



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA PODNIKATELSKÁ

FACULTY OF BUSINESS AND MANAGEMENT

ÚSTAV INFORMATIKY

INSTITUTE OF INFORMATICS

**VYUŽITÍ UMĚLÉ INTELIGENCE JAKO PODPORY
PRO ROZHODOVÁNÍ V PODNIKU**

THE USE OF ARTIFICIAL INTELLIGENCE FOR DECISION MAKING IN THE FIRM

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Michal Seryj

VEDOUCÍ PRÁCE

SUPERVISOR

prof. Ing. Petr Dostál, CSc.

BRNO 2019

Zadání diplomové práce

Ústav: Ústav informatiky
Student: **Bc. Michal Seryj**
Studijní program: Systémové inženýrství a informatika
Studijní obor: Informační management
Vedoucí práce: **prof. Ing. Petr Dostál, CSc.**
Akademický rok: 2018/19

Ředitel ústavu Vám v souladu se zákonem č. 111/1998 Sb., o vysokých školách ve znění pozdějších předpisů a se Studijním a zkušebním řádem VUT v Brně zadává diplomovou práci s názvem:

Využití umělé inteligence jako podpory pro rozhodování v podniku

Charakteristika problematiky úkolu:

Úvod
Vymezení problému a cíle práce
Teoretická východiska práce
Analýza problému a současné situace
Vlastní návrhy řešení, přínos návrhů řešení
Závěr
Seznam použité literatury
Přílohy

Cíle, kterých má být dosaženo:

Vymezení řešeného problému a stanovení celkového a dílčích cílů. Provedení teoretického popisu základů použité teorie prostředků umělé inteligence, popis a analýza problému, vyhodnocení současné situace, provedení návrhu řešení a zhodnocení přínosu návrhu řešení.

Základní literární prameny:

DOSTÁL, P. Advanced Decision Making in Business and Public Services. Brno: CERM, 2011. 168 s. ISBN 978-80-7204-747-5.

DOSTÁL, P. Pokročilé metody rozhodování v podnikatelství a veřejné správě. Brno: CERM, 2012. 718 s. ISBN 978-80-7204-798-7.

HANSELMAN, D. a B. LITTLEFIELD. Mastering MATLAB. Pearson Education International Ltd., 2012. 852 s. ISBN 978-0-13-185714-2.

MAŘÍK, V., O. ŠTĚPÁNKOVÁ a J. LAŽANSKÝ. Umělá inteligence. Praha: ACADEMIA, 2013. 2473 s.
ISBN 978-80-200-2276-9.

Termín odevzdání diplomové práce je stanoven časovým plánem akademického roku 2018/19

V Brně dne 28.2.2019

L. S.

doc. RNDr. Bedřich Půža, CSc.
ředitel

doc. Ing. et Ing. Stanislav Škapa, Ph.D.
děkan

ABSTRAKT

Diplomová práca sa venuje predpovedi konverzného kurzu mien, využitím prostriedkov umelej inteligencie ako pomoc pri rozhodovaní v podnikateľstve a verejnej správe. Konkrétne využitie tejto predikcie je aplikované do praxe pre firmu TechPlasty s.r.o. V práci je obsiahnutá analýza vstupných dát, optimalizácia predikčného modelu a vyhodnotenie prínosu výsledkov pre konkrétnu spoločnosť.

ABSTRACT

Diploma thesis deals with design of a model for currency rate prediction by using artificial intelligence as a tool for decision making process in business and public administration. Concrete usage of this prediction is applied in company TechPlasty s.r.o. The thesis focuses on analysis of input data, optimization of a prediction model and evaluation of the results and their profit for the selected company.

KĽÚČOVÉ SLOVÁ

Umelá inteligencia, neurónové siete, predikcia, NeuroXL Predictor, rozhodovací systém

KEY WORDS

Artificial intelligence, neural networks, prediction, NeuroXL Predictor, decision making system

BIBLIOGRAFICKÁ CITÁCIA

SERYJ, Michal. *Využití umělé inteligence jako podpory pro rozhodování v podniku* [online]. Brno, 2019 [cit. 2019-05-10]. Dostupné z: <https://www.vutbr.cz/studenti/zav-prace/detail/117561>. Diplomová práce. Vysoké učení technické v Brně, Fakulta podnikatelská, Ústav informatiky. Vedoucí práce Petr Dostál.

ČESTNÉ PREHLÁSENIE

Vyhlasujem, že som záverečnú prácu na tému „Využitie umelej inteligencie ako podpory pri rozhodovaní v podniku“ vypracoval samostatne, pod vedením vedúceho práce a uviedol som všetky zdroje, z ktorých som čerpal.

V Brne dňa 12.5.2019

.....

podpis študenta

POĎAKOVANIE

Týmto by som chcel poďakovať vedúcemu svojej diplomovej práce prof. Ing. Petrovi Dostálovi, CSc. za ochotu, vynaložený čas a poskytnuté rady pri vypracovaní tejto práce.

OBSAH

Úvod	10
Ciele práce a metodika	11
1 Teoretické východiská práce	12
1.1 Optimalizácia	12
1.2 Umelá inteligencia.....	13
1.3 Fuzzy logika.....	13
1.4 Proces fuzzy spracovania.....	15
1.5 Využitie fuzzy logiky	15
1.6 Predikcia	16
1.7 Neurónové siete.....	18
1.7.1 Aktivačné funkcie.....	21
1.7.2 Využitie neurónových sietí	24
2 Analýza súčasného stavu	27
2.1 Predstavenie vybranej spoločnosti	27
2.2 Hierarchia spoločnosti	28
2.3 Analýza interných faktorov pomocou modelu 7S.....	29
2.4 SLEPT Analýza.....	32
2.5 Porterov model 5 síl	33
2.6 SWOT Analýza	35
3 Riadená zmena v spoločnosti	38
3.1 Identifikácia zmeny	38
3.2 Výber konkrétneho riešenia	38
3.3 Lewinov model	39
3.4 Fáze intervencie a vlastná zmena.....	39
3.5 Verifikácia dosiahnutých výsledkov	40
3.6 Metóda PERT.....	40
3.7 Časová analýza zmeny	41
3.8 Riziková analýza	43
3.9 Analýza a ohodnotenie rizík	43
3.10 Mapa rizík	44

4	Návrh riešenia	48
4.1	Výber vhodného programu	48
4.2	Vstupné dáta.....	49
4.2.1	Časové obdobie vstupných dát pre predikciu	52
4.3	Riešenie nástrojom NeuroXL Predictor	54
4.3.1	Proces trénovania siete	56
4.4	Porovnanie jednotlivých predikcií	61
4.4.1	Porovnanie podľa začiatku časového radu	62
4.4.2	Porovnanie podľa počtu neurónov v skrytej vrstve.....	64
4.5	Výsledná predikcia	66
5	Vyhodnotenie prínosu	70
5.1	Ekonomický prínos	71
	Záver	74
	Zdroje	75
	Zoznam obrázkov	77
	Zoznam tabuliek	79
	Zoznam príloh	80

ÚVOD

Táto diplomová práca sa venuje využitiu pokročilých metód soft computingu, konkrétne prvkov umelej inteligencie v praxi. Na základe analýzy konkrétnej spoločnosti bola vybraná oblasť, v ktorej by bolo využitie umelej inteligencie prínosom.

Pre každú spoločnosť, ktorá uskutočňuje medzimenové platby, či už má v cudzej krajine založený účet, z ktorého faktúry uhrádza, alebo platí faktúry jednotlivo priamo z účtu vedeného vo svojej krajine, má hodnota konverzného kurzu v deň uhradenia faktúry priamy vplyv na jej náklady, tým pádom aj zisk.

Vybraná spoločnosť TechPlasty s.r.o. niekoľkokrát mesačne v nepravidelných intervaloch objednáva tovar, prevažne od dodávateľov sídlacích v Maďarsku. Mesačné náklady spoločnosti sú rádovo v desiatkach tisícoch eur a tak môže predikcia kurzu a následný výber dňa splatnosti mať pozitívny vplyv na minimalizovanie nákladov spojených s konverziou meny.

CIELE PRÁCE A METODIKA

Cieľom diplomovej práce je na základe analyzovania súčasného stavu vybranej spoločnosti TechPlasty s.r.o., optimalizovať model využívajúci prvky umelej inteligencie, ktorý bude prínosom pre rozhodovací proces, spojený s úhradou faktúr zahraničným dodávateľom.

Práca v úvode popisuje teoretické východiská danej problematiky, ktoré boli využité pri spracovaní ďalších častí práce, takisto sú v úvodnej kapitole predstavené prínosy umelej inteligencie aj konkrétne využitie jednotlivých prvkov, ktoré sú definované.

V druhej kapitole práce je predstavená spoločnosť, pre ktorú bude riešenie implementované, analýza súčasného stavu tejto spoločnosti, ale aj ich rozhodovací proces spojený s úhradou faktúr v cudzej mene.

Na základe analýzy súčasného stavu je ďalej navrhnutá zmena, vrátane časového plánu jej implementácie a je optimalizovaný model neurónových sietí pre predikciu konverzného kurzu domácej a cudzej meny, konkrétne eura a forintu.

V záverečnej kapitole je potom vyhodnotená úspešnosť danej predikcie, ale aj prínos rozhodnutí vytvorených na základe predikčného modelu neurónovej siete, teda zmena nákladov, ktorá bola týmto rozhodnutím dosiahnutá.


1 TEORETICKÉ VÝCHODISKÁ PRÁCE

V tejto kapitole je spracovaná teória a definície jednotlivých pojmov, ktoré sú využívané v práci.

Úvodná časť je zameraná na umelú inteligenciu všeobecne, ďalšie časti sa potom venujú jednotlivým prvkom umelej inteligencie.

1.1 Optimalizácia

Optimalizácia je matematická disciplína, v ktorej hľadáme maximum alebo minimum funkcie danej na množine M , takáto funkcia sa nazýva účelová funkcia. Množina prípustných riešení je ohraničená obmedzeniami, ktoré sú sformulované do sústavy rovníc, prípadne nerovníc. Takéto rovnice a nerovnice sa nazývajú súhrnne štrukturálne podmienky. Cieľom tak je nájsť globálne a nie lokálne maximum, resp. minimum, za účelom nájdenia najlepšej hodnoty účelovej funkcie, s ohľadom na typ úlohy, pre ktorú sa optimalizácia vykonáva.



Obrázok 1 Rozdiel medzi globálnym a lokálnym extrémom¹

¹ Maxima and minima of functions [online]. [cit. 2019-05-08]. Dostupné z: <http://xaktly.com/CurveSketching.html>

1.2 Umelá inteligencia

Pojem umelá inteligencia sa začal formulovať v polovici dvadsiateho storočia. Umelá inteligencia je jednou z najrýchlejšie sa vyvíjajúcich vedeckých a technických disciplín.

Umelá inteligencia je vlastnosť umelo vytvoreného systému, ktorý má schopnosť rozpoznávať predmety a javy, analyzovať vzťahy medzi nimi a tak si vytvárať modely sveta, robiť účelové rozhodnutia a predvídať ich dôsledky, riešiť problémy vrátane objavovania nových zákonitostí a zdokonaľovania svojej činnosti.²

Pre umelú inteligenciu ako vednú disciplínu je špecifické to, že sa nejedná o disciplínu s pevne vymedzeným a zjednoteným teoretickým základom. Jedná sa skôr o súbor metód, teoretických prístupov a algoritmov, ktoré zjednocujú úsilie o počítačové riešenie veľmi zložitých úloh.

Typické pre umelú inteligenciu je aj to, že dosiahnutie výsledkov v riešení čiastkových problémov predstavujú tieto výsledky byť súčasťou umelej inteligencie a prechádzajú plynule do iných oborov, kde sú aplikované, alebo slúžia k formovaniu nových, samostatných vedných disciplín.

Napríklad rozvoj niektorých učiacich sa algoritmov je dnes už neoddeliteľnou súčasťou modernej teórie automatického riadenia. Techniky reprezentácie a využívania znalostí tvoria základ modernej, znalostne orientovanej časti softvérového inžinierstva.

1.3 Fuzzy logika


Teória fuzzy logiky bola prvýkrát predstavená v roku 1965 profesorom Lotfi Zadehom na Kalifornskej univerzite.³ Jej názov pochádza z anglického slova

² MAŘÍK, Vladimír, Olga ŠTĚPÁNKOVÁ a Jiří LAŽANSKÝ. *Umelá inteligencia*. Praha: Academia, 1993-., s.18 ISBN 80-200-0496-3.

³ DOSTÁL, Petr. *Soft computing v podnikatelsví a veřejné správě*. 2015. Brno: Akademické nakladatelství CERM, 2015, str. 22. ISBN 978-80-7204-896-0.

„fuzzy“ a znamená neurčitý, alebo nejasný, čo priamo súvisí s jej princípom. Fuzzy logika rozoznáva aj iné, než len pravdivé a nepravdivé hodnoty, reprezentované hodnotami 0 a 1.

Pracuje s celým intervalom $<0;1>$, a tak obsahuje nekonečne veľa prvkov. Fuzzy číslo z tohoto intervalu nereprezentuje hodnotu reálneho čísla, ale to, ako veľmi daný prvok patrí do množiny. Táto logika sa nazýva viachodnotová, týmto prístupom je možné pracovať s významom slov prirodzeného jazyka a využíva sa pri riešení návrhu zložitých systémov.⁴



Obrázok 2 Priradovanie hodnôt vo fuzzy logike⁵

Na uvedenom príklade je na obrázku ukázané, ako pomocou fuzzy logiky je priradená mužovi hodnota, z celého intervalu $<0;1>$ vzhľadom na jeho výšku a hmotnosť. Podľa klasickej teórie množín by muž do skupiny vysokých ľudí buď patrila, alebo nie. Vo fuzzy logike do tejto skupiny patrí, s určitou hodnotou príslušnosti.⁶

⁴ DOSTÁL, Petr. *Soft computing v podnikateľsví a verejné správě*. 2015, str. 7-10. Brno: Akademické nakladatelství CERM, 2015. ISBN 978-80-7204-896-0.

⁵ *Lecture operations and rules of fuzzy sets* [online]. [cit. 2019-05-08]. Dostupné z: http://www.philadelphia.edu.jo/academics/qhamarsheh/uploads/Lecture%2019_Operations%20and%20rules%20of%20fuzzy%20sets.pdf

⁶ DOSTÁL, Petr. *Soft computing v podnikateľsví a verejné správě*. 2015. Brno: Akademické nakladatelství CERM, 2015, str. 22. ISBN 978-80-7204-896-0.

1.4 Proces fuzzy spracovania


Proces systému s fuzzy logikou obsahuje tri základné kroky: fuzzifikáciu, fuzzy interferenciu a defuzzifikáciu.

Fuzzifikácia znamená prevod reálnych premenných na jazykové premenné. Definícia jazykových premenných vychádza z lingvistickej premennej. Napríklad riziko môžeme rozlišovať žiadne, veľmi nízke, nízke, stredné, vysoké, alebo veľmi vysoké. Obvykle sa používa tri až sedem atribútov premennej.

Fuzzy interferencia definuje chovanie systému pomocou pravidiel typu <Keď>, <Potom>, <S váhou> na jazykovej úrovni. V týchto algoritmoch sa objavujú podmienkové vety, ktoré vyhodnocujú stav príslušnej premennej.

Výsledkom fuzzy interferencie je jazyková premenná. V prípade analýzy rizika môžu mať atribúty hodnoty napríklad veľmi nízke, nízke, stredné, vysoké, alebo veľmi vysoké, čo môže viesť k výstupom jako uskutočniť, alebo neuskutočniť investíciu.

Defuzzifikácia prevádza výsledok operácie fuzzy interferencia na reálne hodnoty. Reálnou akciou môže byť stanovenie výšky rizika. Cieľom defuzzifikácie je prevedenie fuzzy hodnoty výstupnej premennej tak, aby slovne čo najlepšie reprezentovala výsledok fuzzy výpočtu.



Obrázok 3 Proces fuzzy spracovania⁷

1.5 Využitie fuzzy logiky

Pomocou fuzzy logiky je možné riešiť najrôznejšie prípadové štúdie. Napríklad sa jedná o výber banky za účelom poskytnutia úveru a pôžičky, vyhodnotenie

⁷ Vlastné spracovanie podľa: DOSTÁL, Petr. *Soft computing v podnikateľsví a verejné správě*. 2015, str. 22. Brno: Akademické nakladatelství CERM, 2015. ISBN 978-80-7204-896-0.

bonity klienta bankou pre poskytnutie úveru, alebo pôžičky, vyhodnotenie akcií, kurzov mien, komodít investícií advokátnej kancelárie, výber mobilného operátora, ale aj filmov, počítaču, voňavky a mnoho ďalších.⁸

1.6 Predikcia

V mnohých ohľadoch ľudskej činnosti je veľmi potrebná znalosť budúceho chovania rozličných veličín. Niektoré metódy na zisťovanie chovania týchto veličín sú založené na princípe algoritmov, prípadne heuristickom prístupe. V umelej inteligencii sa využíva schopnosť učiť sa. Najväčšie využitie v ekonomickej oblasti majú predikcie budúceho vývoja finančných a ekonomických ukazovateľov z oblasti makro a mikroekonomiky ako napríklad: predikcia cien akcií, komodít, hodnôt indexov, konverzných kurzov mien, predaja výrobkov, ale aj demografického vývoja a podobne.

Prvým krokom predikcie je špecifikácia daného predikčného problému. Je dôležité získať dostatočné znalosti o veličinách predikcie, dostupných dátach pre predikciu a takisto ich povahe. Dôležitá je najmä perioda vzorkovania a ich prenosť, ale aj kedy a v akej podobe sú dáta dostupné. Ďalším krokom je zvolenie metódy a časového horizontu predikcie, takisto či, a akým spôsobom budú dáta upravené pre výpočet. Keďže predikcia je len podkladom pre ďalšie rozhodovanie, je potrebné na jej správne vyhotovenie a následne rozhodnutie, vedieť o celom systéme, pre ktorý je predikcia robená, čo najviac.

Ekonomické a finančné procesy patria medzi tie najzložitejšie, pretože ich hodnota závisí od faktorov, ktoré spoločnosť ovplyvňuje svojim chaotickým chovaním. V týchto prípadoch je tvorba predikcie náročná a tak sa používajú pokročilé metódy pre získanie kvalitných výsledkov. Takisto je vhodné do predikcie nezahrňať dáta získane v takom časovom intervale, v ktorom došlo k nepredvídateľnému (stochastickému javu), ktorý výrazne ovplyvnil hodnotu skúmanej veličiny.

⁸ DOSTÁL, Petr. *Soft computing v podnikatelsví a veřejné správě*. 2015, str. 109. Brno: Akademické nakladatelství CERM, 2015. ISBN 978-80-7204-896-0.

Medzi tieto pokročilé metódy patrí fuzzy logika, neurónové siete a evolučné(genetické) algoritmy, tieto metódy sa využívajú buď oddelene, alebo aj v ich vzájomnej kombinácii.⁹

Predikcia je proces, ktorý začína pred udalosťou, prebieha pri procese a končí po udalosti. Veľmi dôležité tak je vyhodnotovanie kvality predikčného modelu, ktoré sa realizuje na základe znalosti hodnôt skutočných a predikovaných.

Na toto vyhodnotenie sa využívajú rôzne kritéria, najčastejšie používané sú: metóda strednej kvadratickej chyby MSE (mean squared error), strednej absolútnej chyby MAE (mean absolute error) a strednej relatívnej chyby $MAPE$ (mean absolute percentage error) vyjadrenej v percentách.¹⁰

Krátkodobá predikcia, napríklad na najbližší deň, vykazuje lepšie výsledky a menšiu hodnotu strednej chyby, ako predikcia napríklad na najbližší mesiac.¹¹

Vzorce pre ich výpočet sú nasledovné:

$$MSE = \frac{1}{N} \sum_{t=1}^N \left(x_t - \hat{x}_t \right)^2,$$

$$MAE = \frac{1}{N} \sum_{t=1}^N \left| x_t - \hat{x}_t \right|,$$

$$MAPE = \frac{100}{N} \sum_{t=1}^N \left| \frac{x_t - \hat{x}_t}{x_t} \right|,$$

⁹ DOSTÁL, Petr. *Soft computing v podnikatelsví a veřejné správě*. 2015., str. 693-695 Brno: Akademické nakladatelství CERM, 2015. ISBN 978-80-7204-897-7.

¹⁰ DOSTÁL, Petr, Karel RAIS a Zdeněk SOJKA. *Pokročilé metody manažerského rozhodování: konkrétní příklady využití metod v praxi*. Praha: Grada, 2005., s.114 Expert (Grada). ISBN 80-247-1338-1.

¹¹ DOSTÁL, Petr. *Neural Networks and the Shares* [online]. In: ., s. 5 [cit. 2019-05-03]. Dostupné z: <http://www.petrdostal.eu/papers/cla06.pdf>

Kde x_t je skutočná hodnota a \hat{x}_t je hodnota vypočítaná predikciou.¹²

1.7 Neurónové siete

Umelé neurónové siete sú nedokonalým modelom myslenia ľudského mozgu. Neurónové siete sú označované termínom „čierna skrinka“, pretože sa nedá rozpoznať detailne vnútorná štruktúra systému. Na vnútorný systém je kladených niekoľko predpokladov, ktoré umožnia popísať chovanie systému funkciami, ktorá vykonávajú vstupno výstupnú transformáciu.


Čierna skrinka pracuje v dvoch fázach. V prvej fáze sa učí nastaviť svoje parametre tak, aby čo najlepšie vyhovovali požadovanej topológii siete. V druhej fáze na základe získaných znalostí produkuje výstupy získane vo fáze prvej.¹³

Tento postup je možné porovnať so správaním človeka, ktorý je v určitej oblasti nezaučený. Na základe nadobudnutých skúseností a udalostí, ktoré nastali sa z neho stáva v danej oblasti odborník, teda absolvoval obe fázy rovnako ako čierna skrinka.

Biologický aj umelý neurón je systém so vstupmi a výstupmi. Nervové bunky na seba naväzujú a posúvajú si informácie vo forme elektrických a chemických procesov. Funkčné spojenie nervových vlákien biologických neurónov sa nazýva synapsia.

¹² DOSTÁL, Petr. *Soft computing v podnikatelsví a veřejné správě*. 2015., str. 695 Brno: Akademické nakladatelství CERM, 2015. ISBN 978-80-7204-897-7.


¹³ DOSTÁL, Petr. *Soft computing v podnikatelsví a veřejné správě*. 2015., str. 111-112 Brno: Akademické nakladatelství CERM, 2015. ISBN 978-80-7204-896-0.



Obrázok 4 Biologický neurón¹⁴

Umelý neurón je založený na princípe biologického neurónu. Ich porovnanie je možné len z hľadiska základných princípov ich fungovania.

¹⁴ Prednaska Neuronove siete [online]. Bratislava [cit. 2019-05-09]. Dostupné z: <http://uamt.fe.i.stuba.sk/MVI/sites/default/files/Prednaska%204%20Neuronove%20siete.pdf>



Obrázok 5 Umelá neurónová sieť¹⁵

Takýto model sa nazýva perceptron. Jedná sa o najjednoduchší model neurónovej siete. Perceptron má n vstupov, ktoré tvoria vstupný vektor neurónu, do ktorého privádzajú informácie buď z vonkajšieho prostredia, alebo z iného neurónu. Jednotlivé vstupy sú reprezentované hodnotami, reálnymi číslami, a takisto váhami w , ktoré ohodnocujú dôležitosť konkrétneho vstupu. Hodnota vstupu spolu s jeho váhou sú medzi sebou vynásobené. Platí teda nasledovný vzťah:

$$Y = f\left(\sum_{i=1}^N w_i x_i + bias\right) \quad 16$$

K sume násobkov hodnôt x a váh w je pripočítaná prahová hodnota bias.

¹⁵ Vlastné spracovanie podľa: MAŘÍK, Vladimír, Olga ŠTĚPÁNKOVÁ a Jiří LAŽANSKÝ. *Umelá inteligencia*. Praha: Serifa, 2003, s. 204. ISBN 80-200-1044-0.


¹⁶ DOSTÁL, Petr. *Soft computing v podnikatelsví a veřejné správě*. 2015., s. 114 Brno: Akademické nakladatelství CERM, 2015. ISBN 978-80-7204-896-0.

1.7.1 Aktivačné funkcie

Aktivačná, alebo transformačná funkcia, je funkcia, ktorá výslednú hodnotu transformuje na výstupnú hodnotu.


Aktivačné funkcie sú rôzne, medzi najčastejšie využívané patria hardlim, purelin, logsig, tansig, harlins, satlin, satlins a radbas.¹⁷

hardlim



Hard-Limit Transfer Function


purelin



Linear Transfer Function

¹⁷ DOSTÁL, Petr. *Soft computing v podnikatelsví a veřejné správě*. 2015. Brno: Akademické nakladatelství CERM, 2015, s. 114. ISBN 978-80-7204-896-0.


logsig



$$a = \text{logsig}(n)$$

Log-Sigmoid Transfer Function


tansig



$$a = \text{tansig}(n)$$

Tan-Sigmoid Transfer Function


hardlims



$$a = \text{hardlims}(n)$$


Symmetric Hard-Limit Trans. Funct.

satlin




Satlin Transfer Function

satlins




Satlins Transfer Function

radbas



Radial Basis Function

tribas



Obrázok 6 Grafy aktivačných funkcií¹⁸

1.7.2 Využitie neurónových sietí

Neurónové siete majú široké využitie, ktoré je možné nájsť v rôznych podnikateľských aplikáciach a verejnej správe.

Ekonomická a sociálna oblasť

Hlavným využitím neurónových sietí, spojeným s touto prácou je predikcia časového radu určitých hodnôt. Neurónové siete sú súčasťou nástrojov na predikciu budúcej ceny komodity pri obchodovaní na burze, ale takisto pri predikovaní spotreby určitej veličiny v budúcnosti, napríklad tepla, vody, elektriny atď.

V sociálnej oblasti sa využívajú na určenie predpokladaného vývoju demografickej krivky, zamestnanosti, výške dôchodku a podobne.¹⁹

Sociálne siete

Stále zvyšujúci sa počet užívateľov sociálnych sietí a tým pádom aj rastúce množstvo dát, ktoré na sociálne siete títo užívatelia nahrávajú, umožňuje tvorcom

¹⁸ *Transfer function graphs* [online]. University San Diego, 2015 [cit. 2019-05-06]. Dostupné z: <https://edoras.sdsu.edu/doc/matlab/toolbox/nnet/tables14b.html#7752>

¹⁹ DOSTÁL, Petr. *Soft computing v podnikateľstve a verejnej správe*. 2015., s.111-182 Brno: Akademické nakladatelství CERM, 2015, s. 114. ISBN 978-80-7204-896-0.

týchto médií s dátami pracovať ako so vstupmi pre neurónové siete.

Napríklad pri nahratí fotografie na sociálnu sieť Facebook, je pomocou neurónovej siete detekovaná tvár človeka.

Využitie neurónových sietí je takisto možné nájsť aj na Instagrame, kde na základe napísaného textu aplikácia odporúča emotikon, ktorý užívateľ pravdepodobne bude chcieť vložiť, jedná sa síce o jednoduchú aplikáciu neurónovej siete, ale jej využitie pre ďalšiu analýzu je významné.

Online nakupovanie

Pri vyhľadávaní jednotlivých výrazov, ktoré opisujú produkt, ktorý si užívateľ chce kúpiť, sú mu automaticky ponúknuté výsledky vyhľadávania, ktoré súvisia s jeho predchádzajúcimi vyhľadávaniami. Napríklad ak je pravidelne do vyhľadávača zadávaný názov určitého mobilného telefónu v rôznych spojeniach a neskôr je do vyhľadávania nabíjačka na mobilný telefón, vyhľadávač pomocou neurónovej siete odporučí výsledky s nabíjačkou na v minulosti vyhľadávaný telefón.

Odporúčania

Odporúčania fungujú podobne, napríklad na základe predchádzajúcich nákupov sú odporúčané ďalšie produkty vo forme „zákazníci ktorý kúpili tento produkt kúpili takisto...“. Tieto odporúčania sú možné vďaka neurónovým sieťam. Spoločnosť Amazon napríklad využíva trénovacie algoritmy na zistenie správania svojich zákazníkov.

Bankovníctvo

Väčšina veľkých bánk už nevyžaduje po klientoch časté návštevy pobočky za účelom doručenia šeku alebo platobného príkazu. Túto úlohu momentálne plnia aj smartphone aplikácie, ktorých technológie využívajú neurónové siete na dešifrovanie a konvertovanie dát. Každá aplikácia, ktorá je pracuje s overením hlasu, alebo podpisu využíva model neurónovej siete.

Banky takisto využívajú neurónové siete na predikciu podvodných transakcií. Pri veľkom množstve každodenných transakcií by nebolo možné ich manuálne kontrolovať a tak sú rôznymi spoločnosťami vyvíjané nástroje, ktoré na základe

frekvencie a výšky transakcie a strán, ktoré sa obchodu zúčastňujú, vyhodnocujú dôveryhodnosť transakcií.

Ďalšími praktickými aplikáciami neurónových sietí sú napríklad aplikácie v telefóne umožňujúce prevod hovoreného slova na text, táto technológia má následne ďalšie využitie v podobe „asistentov“ vo forme aplikácií, ktorý na základe hovoreného slova dokážu vyhľadávať na internete, alebo editovať osobný kalendár.²⁰

²⁰ CHANDRA, Reetesh. *Neural networks applications in the real world* [online]. [cit. 2019-05-09]. Dostupné z: <https://www.upgrad.com/blog/neural-networks-applications-in-the-real-world/>

2 ANALÝZA SÚČASNEHO STAVU

V druhej kapitole je predstavená zvolená spoločnosť, pre ktorú je predikcia vyhotovená, ako počet zamestnancov, základné imanie, sídlo a predmet podnikania. Ďalej je analyzovaný súčasný stav spoločnosti a ich rozhodovacie procesy vo vzťahu k uhrádzaniu pohľadávok v cudzej mene.

2.1 Predstavenie vybranej spoločnosti



Obrázok 7 Logo spoločnosti TechPlasty²¹

Obchodné meno: TechPlasty s.r.o.

Sídlo: Hričovská 17, Žilina 010 01, Slovensko

IČO: 68 259 648

Deň zápisu do obchodného registru: 01.01.1993

„Predmetom podnikania spoločnosti TechPlasty je predaj polotovarov z technických plastov výroba a predaj strojných súčiastok podľa katalógov, zákazková výroba strojných súčiastok, dielov a kompletov.

Firma TechPlasty okrem vlastných výrobkov dodáva výrobky firiem: Najväčších svetových výrobcov technických plastov, dosky, tyče, trubky, pásy, fólie, prířezy, hotové výrobky Rexnord, plastové a kovové doštičkové reťaze, modulárne a flexibilné reťaze, diely pre dopravníky, pätky, ložiskové

²¹ TechPlasty [online]. Žilina [cit. 2019-05-09]. Dostupné z: <https://www.techplasty.sk>

domce, plastové a kovové doštičkové reťaze, modulárne a flexibilné reťaze Esbelt, dopravné pásy Linaset, ovládacie prvky Alwayse Anglicko a guľôčkové dopravné jednotky. Sídlo firmy TechPlasty je v Žiline.

Firma zamestnáva skúsených technologov a konštruktérov, ktorí sú schopní riešiť spolu s technickými pracovníkmi zákazníkove technologické problémy na ich linkách priamo vo výrobe a navrhnuť riešenia pomocou nami dodávaných a vyrábaných dielov. Zákazníkmi spoločnosti sú firmy v Slovenskej a Českej Republike zo všetkých odvetví priemyslu (potravinársky, strojársky, automobilový, stavebný, spracovanie dreva a výroba nábytku, chemický, textilný a iné).²²

2.2 Hierarchia spoločnosti

V spoločnosti je momentálne jediný konateľ, ďalej niekoľko technických pracovníkov, ktorí komunikujú s klientmi a na základe ich požiadaviek vyhotovujú objednávky a zadávajú ich do výroby, ktorá je spojená so sklado. Technickí pracovníci pri vyhotovení objednávky zároveň kontrolujú, zostatok materiálu, z ktorého výroba bude prebiehať a v prípade poklesnutia tohto množstva objednávajú tovar, od stálych dodávateľov, prevažne z Maďarska.


Takto objednaný tovar je dodaný zvyčajne s dodacou lehotou dvoch týždňov a faktúra za tento tovar má dobu splatnosti 30 dní.

V súčasnosti rozhoduje o presnom termíne splatnosti vedenie firmy, teda jej konateľ a to bez využitia predikcie na vývoj kurzu. Spoločnosť má účty vedené na Slovensku v eurách. Konkrétny termín v ktorom sú takéto faktúry uhradené je tak zvolený len na základe každodenného kontrolovania kurzu a porovnania s predošlými dňami.

²² *TechPlasty – technické plasty*[online]. Žilina [cit. 2019-05-09]. Dostupné z: <https://www.techplasty.sk>

2.3 Analýza interných faktorov pomocou modelu 7S

Analýza interných faktorov 7S hodnotí spoločnosť zo siedmich uvedených faktorov, ktoré spolu vzájomne súvisia. Tieto faktory vypovedajú o úspechu danej spoločnosti.



Obrázok 8 Model 7S²³

Stratégia

Dlhodobou stratégiou spoločnosti je ponúkať kvalitné výrobky s nízkou mierou

²³ RAIS, K. a R. DOSKOČIL. Risk Management. Brno: CERM, 2007, s.13. ISBN 978- 80-214-3510-0.

chybovosti, a tak udržiavať dlhodobých zákazníkov, ktorí majú výhodnejšie podmienky, prípadne množstevné zľavy. Keďže sú výrobky spoločnosti zväčša určené na ďalšiu úpravu, sú práve dlhodobí zákazníci, v podobe veľkých firiem najvýznamnejšou skupinou.

Spoločnosť takisto pracuje na získavaní nových zákazníkov. Niektorí technickí pracovníci trávajú väčšinu na pracovných cestách, kde je ich úlohou prezentovať výrobky spoločnosti a prípadne navrhovať oblasti kde by bolo pre danú firmu vhodné ich uplatnenie.

Dlhodobé zábery sú založené na vyše 20 ročnej tradícii firmy a jej kvalitu výrobkov a ponúkaných služieb.

Štruktúra

Zakladateľ firmy je zároveň jej konateľom a prijíma dôležité manažérske rozhodnutia. Najpočetnejšou skupinou sú technickí pracovníci, vyštudovaní strojár, ktorí majú na starosti objednávky a sú zodpovední za procesy spojené s nimi. Súčasťou štruktúry sú takisto pracovníci na sklade, ktorý vyhotovujú produkty podľa konkrétnej objednávky.

Systémy riadenia

Systémom riadenia je primárne informačný systém, vytvorený konateľom spoločnosti, ktorý zahŕňa správu objednávok. Tento informačný systém využívajú všetci pracovníci firmy a slúži na nasledovné účely: informácie o stave tovaru a jeho objednanie pri nedostatku, informácie o klientovi a histórii jeho objednávok, informácie o konkrétnych zákazkách, informácie pre pracovníkom na sklade s poradím objednávok a ich prioritou a ďalšie. Systém je upravovaný a vylepšovaný po pravidelných konzultáciách so zamestnancami, aby čo najviac uľahčoval ich prácu.²⁴

Spoločnosť ďalej na dopravu využíva informačný systém spoločnosti GEIS.

²⁴ RAIS, K. a R. DOSKOČIL. Risk Management. Brno: CERM, 2007, s.20. ISBN 978- 80-214-3510-0.

Štýl riadenia

Riadenie v spoločnosti má nasledovnú formu. Každý pracovník má svojho nadriadeného, ktorému sa zodpovedá za pridelené úlohy, takisto s ním môže riešiť problémy, s ktorými sa pri práci stretne.

Jedná sa o spoločnosť so sídlom v Žiline, kde denne dochádza väčšina zamestnancov, sklad je na rovnakej adrese. Technickí pracovníci, ktorí trávia pracovný čas na cestách, ale aj jednotliví zamestnanci v rámci firmy potrebujú spolu neustále komunikovať, na komunikáciu sa vo firme používa program Jabber. Väčšie debaty na mesačnej báze potom prebiehajú osobne.

Spolupracovníci

Jedná sa o spoločnosť s priateľskou atmosférou, väčšina zamestnancov je vo firme dlhodobo, a tak sú medziľudské vzťahy na dobrej úrovni. V spoločnosti takisto pracuje viacero ľudí, ktorí sú v príbuzenskom vzťahu, prípadne sa poznali už pred príchodom do firmy. Voľné pracovné pozície pri rozširovaní kapacít sa takisto viackrát obsadili ľuďmi odporučenými niektorým zo zamestnancov.

Firemné prostredie a kultúra je podporovaná vedením aj vo forme rôznych teambuildingov, približne dva krát ročne. ²⁵

Schopnosti

Technickí pracovníci firmy sú všetci vyštudovaní strojármi, nakoľko je potrebné aby dokázali posúdiť požiadavku klienta, vedeli čítať technické výkresy a prípadne odporučiť aj neskúseným zákazníkom s vhodným výberom tovaru.

Skladníci, ktorí pripravujú a upravujú materiál, podľa požiadaviek zákazníka, sú manuálne pracujúci so zaškolením na používanie nástrojov, používaných vo výrobe. Riaditeľ spoločnosti má vyštudovanú aplikovanú informatiku, a zodpovedá tak za správny chod hardvéru a softvéru firmy. Vo firme je ešte účtovníčka, ktorá má na toto povolanie takisto potrebné vzdelanie.

²⁵ RAIS, K. a R. DOSKOČIL. Risk Management. Brno: CERM, 2007, s.20. ISBN 978- 80-214-3510-0.

Zdieľané hodnoty

Spoločnosť má za cieľ poskytovať zákazníkom odbornú komunikáciu a kvalitné výrobky a tak medzi základnými hodnotami, ktoré firma presadzuje a kladie nane dôraz sú: profesionalita, odbornosť, ochota, transparentnosť, lojalita a dôveryhodnosť.²⁶

2.4 SLEPT Analýza

SLEPT analýza sa zaoberá vonkajšími vplyvmi pôsobiacimi na spoločnosť. Tieto vplyvy zahŕňajú faktory z oblasti sociálnej, legislatívnej, ekonomickej, politickej a technologickej, z čoho je odvodená skratka SLEPT.²⁷

Sociálne faktory

Demografický vývoj populácie v krajinách, kde spoločnosť pôsobí mierne klesá, avšak zisk firmy, sa medziročne zvyšuje. Takisto v prípade potreby rozšírenia spoločnosti o nových zamestnancov, je v kraji dostatok kvalifikovanej pracovnej sily, a tak sa spoločnosť nestretla s problémom pri výbere z uchádzačov na novo obsadzované pracovné miesto.

Legislatívne faktory

Spoločnosť má sídlo v Slovenskej republike, ale časť klientely má sídlo v Českej republike, preto je nutné poznať zákony, vyhlášky a predpisy, ktoré zahŕňajú vplyv vládnych a politických orgánov. Jedná sa o spoločnosť s ručením obmedzeným a s tým sa spájajú aj normy určené pre tento typ subjektov. Firma musí spĺňať všetky podmienky obchodného a občianskeho zákonníka a takisto dodržiavať často sa meniaci daňový zákon, trestný zákon a zákon o účtovníctve.

²⁶ RAIS, K. a R. DOSKOČIL. Risk Management. Brno: CERM, 2007, s.23. ISBN 978- 80-214-3510-0.

²⁷ PORTER, Michael E. *Konkurenční výhoda: (Jak vytvořit a udržet si nadprůměrný výkon)*. Praha: Victoria Publishing, [1993]. ISBN 80-85605-12-0.

Ekonomické faktory

Keďže spoločnosť sídli na Slovensku, ale dodávateľov má výhradne z Maďarska, je veľmi dôležité sledovať vývoj konverzného kurzu eura voči forintu. Spoločnosť takisto predáva svoje výrobky zákazníkom so sídlom v Českej republike, kde takisto dochádza k platbe v inej mene, na tento účel bol zriadený účet v českých korunách. Peniaze z tohto účtu sú takisto prevedené v nepravidelných intervaloch na účet v domácej mene.

Miera nezamestnanosti v krajinách pôsobenia dlhodobo klesá a takisto aj priemerná a minimálna mzda sa zvyšujú, vplyvom týchto ekonomických faktorov sa kúpna sila zvyšuje, čo sa pozitívne prejavuje na zvyšujúcom sa obrate firmy.

Politické faktory

Strojársky priemysel je na Slovensku v súčasnosti vládou podporovaný. Do krajiny prichádzajú nové firmy, čo je pre spoločnosť priaznivé. Keďže Česká a Slovenská republika sú súčasťou Európskej únie, je aj presun služieb, tovaru a kapitálu pre spoločnosť zjednodušený.

Technologické faktory

V oblasti strojárkeho priemyslu je nutné sledovať technologický pokrok, najmä čo sa týka nových materiálov, prípadne strojov na ich spracovanie a postupy vo výrobe. Takisto dáta, ktoré spoločnosť potrebuje uchovávať musia podliehať bezpečnostným pravidlám, s ohľadom na tento fakt je pravidelne obmeňovaný hardvér za nový. Spoločnosť má bezpečnostný certifikát ISO radu 27000 a tak musí pravidelne kontrolovať podmienky dané týmito normami.

2.5 Porterov model 5 síl

Tento model sa zaoberá vonkajšími faktormi spoločnosti z pohľadu konkurencieschopnosti.²⁸

²⁸ PORTER, Michael E. *Konkurenční výhoda: (Jak vytvořit a udržet si nadprůměrný výkon)*. Praha: Victoria Publishing, [1993]. ISBN 80-85605-12-0.

Odberatelia

Keďže spoločnosť pôsobí na trhu už vyše 20 rokov a väčšina zákazníkov patrí medzi dlhodobých, je vyjednávacía sila takýchto zákazníkov vysoká. Pri dodaní nekvalitných výrobkov, by hrozila strata dobrého mena a prípadne strata zákazníka a jeho presun ku konkurencii.

Dodávatelia

Spoločnosť TechPlasty má dodávateľov plastov, ktoré spracováva, ďalej telekomunikačných a internetových technológií, ale aj dopravných služieb využívaných na odosielanie tovaru zákazníkom. Ponuka jednotlivých služieb je široká a dodávatelia tak nemajú možnosť výraznejšie ovplyvniť cenu. V minulosti napríklad pri zvýšení cien slovenskej pošty, prestala spoločnosť s poštou spolupracovať a začala na distribúciu využívať firmu GEIS.

Nová konkurencia

Vstup nových konkurentov na trh je otvorený a veľmi aktuálny. Veľké podniky však preferujú stabilných a overených dodávateľov a tak by ani prípadný vstup nových subjektov na trh a ich nižšia cena, nemali mať za následok stratu kľúčových zákazníkov. Veľké podniky ako napríklad automobilové závody, nemôžu riskovať kvalitu výrobkov na úkor ceny, ktorá aj tak nebude výrazne odlišná.

Stávajúca konkurencia

Aktuálna konkurencia sa v posledných rokoch značne rozšírila, len v meste Žilina, kde spoločnosť pôsobí, sú aktuálne tri spoločnosti s rovnakým predmetom podnikania. Táto skutočnosť komplikuje najmä získavanie nových zákazníkov a ovplyvňuje podmienky, ktoré sú týmto zákazníkom ponúkané aby sa rozhodli práve pre spoločnosť TechPlasty. Jednotlivé konkurenčné firmy majú iných dodávateľov a postupy pri spracovaní a tak sa spoločnosť snaží získať a udržať zákazníka hlavne kvalitou a dobrým menom vybudovaným za svoje pôsobenie na

trhu.²⁹

Substitúty

Pravdepodobnosť substitúcie niektorých materiálov, ktoré sú ďalej upravované vo výrobe zákazníkom, prípadne sú priamou súčasťou ich produktu, alebo výrobného procesu, je nízka. Každý typ materiálu, ktorý spoločnosť TechPlasty dodáva má svoje vlastnosti a pravidlá, ktoré treba dodržiavať pri ich ďalšej úprave a používaní. V prípade výskytu nových materiálov, ktoré by mohli nahradiť tie aktuálne žiadané, samozrejme spoločnosť bude na takúto zmenu reagovať.

2.6 SWOT Analýza

Silné stránky

- Spoločnosť bola založená v roku 1993 a tak má dlhú tradíciu na trhu
- Zakladateľ firmy je stále jej konateľom a tak je vedená stabilne
- Niektorí zamestnanci sú vo firme takmer od začiatku, ich skúsenosti a schopnosti sú vysoké
- Spoločnosť má stálych zákazníkov aj v podobe veľkých firiem a po presťahovaní sa do väčších priestorov v období minulého roka má potenciál ďalej na trhu rásť
- V spoločnosti sa využívajú moderné nástroje vo výrobe a bezpečnosť zamestnancov je na vysokej úrovni, takisto informačný systém a hardvérové prvky sú pravidelne aktualizované a modernizované
- Medzi zamestnancami je vytvorená dobrá firemná kultúra³⁰

²⁹ PORTER, Michael E. *Konkurenční výhoda: (Jak vytvořit a udržet si nadprůměrný výkon)*. Praha: Victoria Publishing, [1993]. ISBN 80-85605-12-0.

³⁰ FORET, Miroslav. *Marketing pro začátečníky*. Brno: Computer Press, 2008., s.48-49 Praxe manažera (Computer Press). ISBN 978-80-251-1942-6.

Slabé stránky

- Rozhodovacie kompetencie sú v rukách jednej osoby, čo môže niekedy spôsobiť nedostatok času, vplyvom ktorého nie sú prijímané optimálne rozhodnutia
- Strata časti zisku spôsobená prevodom peňazí do zahraničnej meny
- Nízka úroveň marketingových aktivít
- Nekompatibilita operačného systému so softvérom, ktorý by mohol mať pre firmu prínos

Priležitosti

- Rast významu sektoru podnikania spoločnosti a s tým spojený rastúci dopyt po produktoch
- Zakúpenie a následné využitie nových strojov do výroby, čím by sa rozšíril ponúkaný sortiment spoločnosti
- Rastúci počet uchádzačov o štúdium technických oborov, čo následne podporuje rast priemyslu a dopytu po produktoch, takisto je tým zabezpečený dostatok pracovnej sily
- Zintenzívnenie reklamy cielenej na potenciálnych klientov, aj inou formou než osobnou návštevou technického pracovníka u danej spoločnosti
- Zefektívnenie medzi menových presunov financií

Hrozby

- Presun výrobných závodov veľkých firiem do zahraničia
- Nesledovanie trendov v oblasti strojárskeho priemyslu by mohlo oslabiť predaje
- Vznik novej konkurencie, keďže trh strojárskeho priemyslu rastie, dá sa očakávať aj nárast konkurencie
- Spoločný postup stávajúcej konkurencie, ktorého následkom by mohlo dôjsť k znižovaniu cien
- Odchod kľúčových pracovníkov ku konkurenciám, prípadne na penziu

- Strata dobrého mena spoločnosti, napríklad vplyvom zlých recenzií na produkty³¹

Vyhodnotenie SWOT analýzy

- Je treba zlepšiť rozhodnutia spojené s presunom financií medzi účtami v rôznych menách
- Na základe SWOT analýzy je možné predpokladať rast spoločnosti a jej zisku, aj z tohto dôvodu je vhodné, efektívne nakladať s financiami
- Je potrebné zlepšiť marketing aby spoločnosť oslovila firmy, ktoré v najbližšom čase prídu na trh

Výsledky SWOT analýzy naznačujú, že spoločnosť disponuje viacerými príležitosťami, ktoré by viedli k zlepšeniu a silnejšej pozícii na trhu.³²

³¹ FORET, Miroslav. *Marketing pro začátečníky*. Brno: Computer Press, 2008., s.50-52 Praxe manažera (Computer Press). ISBN 978-80-251-1942-6.

³² FORET, Miroslav. *Marketing pro začátečníky*. Brno: Computer Press, 2008., s.50-52 Praxe manažera (Computer Press). ISBN 978-80-251-1942-6.

3 RIADENÁ ZMENA V SPOLOČNOSTI

Zmena, ktorá bude v spoločnosti zavedená je zmenou v rozhodovaní spojeným s prevodom financií medzi účtami vedených v rôznych menách. Táto zmena bude implementovaná vhodným softvérom na vytváranie modelov neurónových sietí.

3.1 Identifikácia zmeny

Spoločnosť v súčasnej dobe uhrádza faktúry so splatnosťou 30 dní maďarským dodávateľom v náhodnom čase, na základe sledovania hodnoty kurzu. V deň, kedy je hodnota kurzu podľa riaditeľa firmy na dobrej úrovni, sú faktúry uhradené. Takýto rozhodovací proces prebieha teda pravidelne a je nutné neustále sledovanie hodnoty konverzného kurz. Rovnaký rozhodovací proces prebieha pri presunutí financií z účtu vedeného v českých korunách, na ktorý prichádzajú platby od českých zákazníkov. Zmenou bude zavedenie systému, alebo programu, ktorý bude slúžiť ako pomoc pri rozhodovaní v súvislosti s týmito činnosťami.³³

3.2 Výber konkrétneho riešenia

Výber konkrétneho programu, ktorý bude vo firme implementovaný prebehol s ohľadom na cenu programu, kompatibilitu s operačným systémom používaným v spoločnosti, ale aj vhodnosťou jednotlivých programov na špecifickú potrebu, ktorou je predikcia konverzného kurzu. Testované boli programy MATLAB, NeuroShell Predictor a NeuroXL Predictor, z ktorých bol vybraný NeuroXL Predictor, ktorý je cenovo najdostupnejší a zahŕňa všetky funkcie potrebné pre vytvorenie potrebnej predikcie.

³³ RAIS, K. a R. DOSKOČIL. Risk Management. Brno: CERM, 2007, s.32. ISBN 978- 80-214-3510-0.

3.3 Lewinov model

Autorom tohto modelu je Kurt Lewin, jedná sa o model pre riadenú zmenu, ktorý zahŕňa správne načasovanie a postupnosť všetkých činností. Nové riešenie, týkajúce sa zavedenia nového programu pre predickiu, je rozdelené do troch krokov.

- Rozmrazenie – príprava zmeny
- Fáza zmeny – priebeh zmeny
- Zmrazenie – ukončenie prebiehajúcej zmeny

Sily pôsobiace za zmenu

- Efektívnejšie využívanie financií
- Zlepšenie časovej náročnosti procesu rozhodovania spojeného s vývojom kurzu
- Predvídateľnosť vývoja kurzu a s tým spojená možnosť tvorenia zásob
- Rýchle zavedenie do prevádzky

Sily pôsobiace proti zmene

- Možné pochybenia pri optimalizácii modelu
- Možné pochybenia pri rozhodnutí na základe modelu

3.4 Fáze intervencie a vlastná zmena

Fázy prebiehajú podľa dopredu pripraveného harmonogramu s postupnou náväznosťou jednej činnosti na druhú. Harmonogram je spracovaný metódou kritickej cesty.³⁴

Fáza rozmrazenia

V tejto fáze je vykonaná analýza súčasnej situácie a na jej základe je rozhodnuté o oblasti, kde má spoločnosť príležitosť na zlepšenie. Po konzultácii s vedením,

³⁴ RAIS, K. a R. DOSKOČIL. Risk Management. Brno: CERM, 2007, s.34. ISBN 978- 80-214-3510-0.

ktoré je jedinou zúčastnenou stranou, je špecifikovaný cieľ zmeny.

Fáza zmeny

Fáza zaoberajúca sa samotnou zmenou a teda implementovaním programu na vytváranie predikcie konverzného kurzu. Vo fáze zmeny je najprv vybraný konkrétny softvér, ktorý bude implementovaný, následne prebehne jeho implementácia za účasti riaditeľa firmy, ktorý ho bude využívať. Po zaškolení je systém zavedený a využívaný ako nástroj na pomoc pri rozhodovacom procese.

Fáza zmrazenia

Jedná sa o konečnú fázu zmeny. V tejto fáze dochádza k overeniu, či sú splnené očakávania, ktoré boli na zmenu kladené a či je vedenie spoločnosti s touto zmenou spokojné.

3.5 Verifikácia dosiahnutých výsledkov

Spôsob overenia prínosu implementovanej zmeny prebieha formou porovnania kurzu, pri ktorom boli financie presunuté, resp. faktúry uhradené, s reálnymi hodnotami kurzu po uplynutí obdobia, na ktoré bola predikcia stanovená. Prínos zmeny by sa takisto dal overiť spokojnosťou konateľa firmy s novým stavom, nakoľko on program využíva a vie posúdiť jeho časovú náročnosť.³⁵

3.6 Metóda PERT

Metóda PERT využíva na rozdiel od metódy kritickej cesty na stanovenie doby trvania čiastkových činností vážený priemer založený na 3 odhadoch: optimistický, realistický a pesimistický. Sieťový graf, ktorý je na tomto princípe postavený je využívaný pokiaľ nie sme schopní s istotou stanoviť dobu trvania. Využitie nájde v projektoch, ktorých podstatou je zmena, v ktorej nejde priebeh vopred predvídať, nakoľko sa nejedná o opakované činnosti. Potrebnými ukazateľmi sú:

³⁵ RAIS, K. a R. DOSKOČIL. Risk Management. Brno: CERM, 2007, s.35. ISBN 978- 80-214-3510-0.

Očakávaná doba trvania činnosti – stredná hodnota

$$t_{ij} = \frac{a_{ij} + 4 * m_{ij} + b_{ij}}{6}$$

smerodajná odchýlka

$$\sigma_{ij} = \frac{b_{ij} - a_{ij}}{6}$$

a rozptyl

$$\sigma_{ij}^2 = \left(\frac{b_{ij} - a_{ij}}{6} \right)^2$$

kde a je optimistický odhad, b pesimistický odhad a m realistický odhad.³⁶

3.7 Časová analýza zmeny

V uvedenej tabuľke sa nachádzajú hodnoty trvania jednotlivých činností. Jednotkou je deň. Celkové trvanie zavedenia zmeny by mala byť 36,5 dní.

Činnosť	Názov činnosti	Následník	a_{ij}	m_{ij}	b_{ij}	t_{ij}	σ_{ij}	σ_{ij}^2
A	Výber programov vhodných pre predickiu	B	0,5	2	5	2,25	0,750	0,563
B	Vytvorenie zoznamu programov a ich ohodnotenie	C	0,375	1	2	1,06	0,271	0,073
C	Výber najoptimálnejšieho programu	D	0,5	2	5	2,25	0,750	0,563
D	Implementácia skúšobnej verzie programu	E,F	0,25	0,5	1	0,54	0,125	0,016
E	Školenie riaditeľa spoločnosti	G	1,5	3,75	6	3,75	0,750	0,563
F	Príprava dát pre vytvorenie predikčného modelu	G	0,25	0,5	1	0,54	0,125	0,016
G	Vytvorenie predikčného modelu	H,I	1	3	5	3,00	0,667	0,444
H	Porovnanie výsledkov predikcie s reálnymi dátami	J	0,5	0,75	2	0,92	0,250	0,063
I	Vylepšenie predikčného modelu	J	0,125	0,75	2	0,85	0,313	0,098
J	Zakúpenie plnej verzie programu	K	0,125	0,25	2	0,52	0,313	0,098
K	Implementácia plnej verzie programu	L	0,25	0,5	1	0,54	0,125	0,016
L	Samostatné fungovanie	M	3	5	7	5,00	0,667	0,444
M	Hodnotenie implementácie	-	10	15	30	16,67	3,333	11,111

Tabuľka 1 Doby trvania jednotlivých činností³⁷

³⁶ RAIS, K. a R. DOSKOČIL. Risk Management. Brno: CERM, 2007, s.61-65. ISBN 978- 80-214-3510-0.

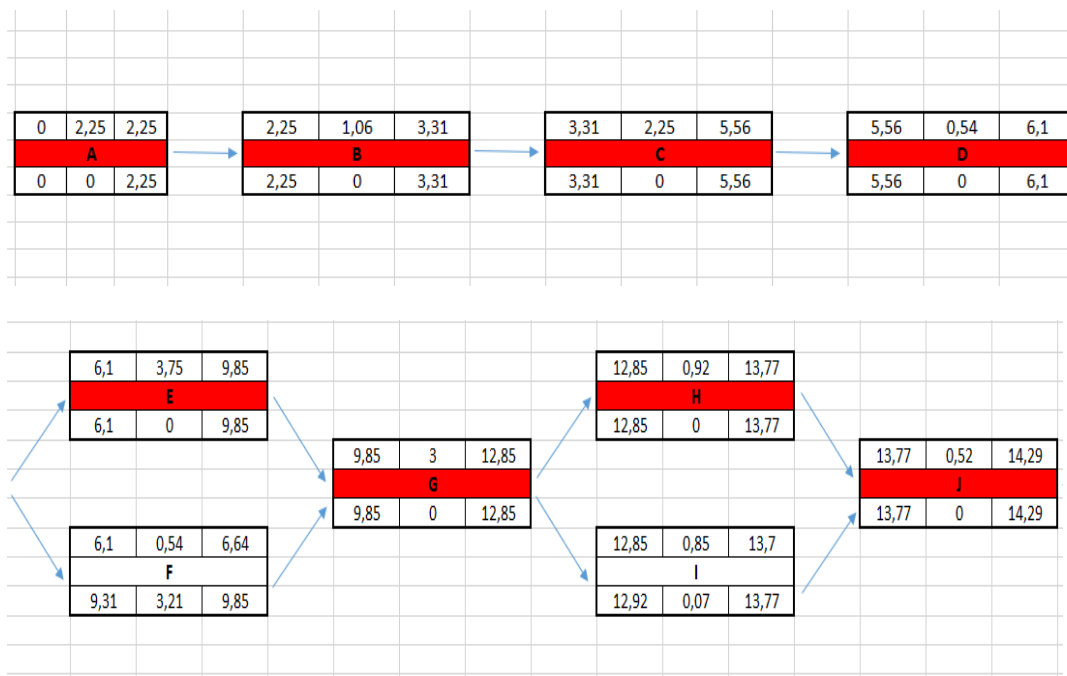
Časová analýza zmeny je vyhotovená pomocou metódy PERT v sieťovom uzlovo orientovanom grafe. Každý uzol vyjadruje jednu konkrétnu činnosť podľa tabuľky 1.

Spôsob výpočtu jednotlivých časových ukazateľov je uvedený na obrázku 8.

ZM = KM predchodcu	Doba trvania	KM=ZM+D
Názov činnosti		
ZP=KP-D	RC=ZP-ZM	KP=ZM nasledovníka


Obrázok 9 Spôsob výpočtu časových ukazateľov v sieťovom grafe³⁸

Výsledný sieťový uzlovo orientovaný graf vyzerá nasledovne:



³⁷ Vlastné spracovanie v MS Excel

³⁸ Vlastné spracovanie v MS Excel



Obrázok 10 Sieťový graf³⁹

3.8 Riziková analýza

Pre zaistenie celkového úspechu zmeny v podobe zavedenia programu NeuroXL Predictor ako súčasti rozhodovacieho procesu, je potrebné vykonať analýzu rizík, ktoré môžu mať vplyv na priebeh implementácie a tým ohroziť cieľ celého projektu.

3.9 Analýza a ohodnotenie rizík

Na analýzu rizík bola vybraná skórovacia metóda, v rámci ktorej sú riziká identifikované, ohodnotené a je daný návrh na zníženie vybraných rizík. Vybrané riziká sú ohodnotené na stupnici od 1 do 10, kde sa pravdepodobnosť a dopad rizika zvyšujú priamo úmerne so zvyšujúcou sa hodnotou tejto stupnice. Celková hodnota jednotlivých rizík je vypočítaná ako súčin hodnôt pravdepodobnosti a dopadu.⁴⁰

³⁹ Vlastné spracovanie v MS Excel

⁴⁰ RAIS, K. a R. DOSKOČIL. Risk Management. Brno: CERM, 2007, s.52-59. ISBN 978- 80-214-3510-0.

ID	Riziko	P	D	H	Opatrenie
Technologické					
1	Nesprávne zvolené vstupné dáta	2	8	16	Zaškolenie počas prípravy modelu ohľadom výberu dát
2	Nedostatočná funkcionálna v skúšobnom režime	2	7	14	Kontrola funkcionality, ktorá je dostupná v skúšobnom režime pri výbere
3	Problém s kompatibilitou programu a operačného systému spoločnosti	3	9	27	Kontrola OS, ktoré sú kompatibilné s programom, pri výbere
4	Nesprávne zvolený program pre predikciu	4	9	36	Jasne definovať požiadavky pred výberom programu
Bezpečnostné					
5	Stiahnutie škodlivých súborov pri získavaní vstupných dát	4	7	28	Používať dáta len z overených zdrojov, prípadne využiť doplnok MS Excel
6	Stiahnutie škodlivého softvéru pri získavaní skúšobnej verzie programu	4	7	28	Skúšobnú verziu programu sťahovať jedine z oficiálnej stránky výrobcu
Finančné					
7	Uhradenie poplatku za program bez získania licencie	2	9	18	Zakúpenie licencie programu len na oficiálnej stránke výrobcu
8	Zvýšenie nákladov pri implementácii programu	2	4	8	Vytvorenie rezervy v rozpočte
Personálne					
9	Riaditeľ firmy bude mať problém pracovať so zavedeným programom samostatne	7	8	56	Počas školenia vysvetliť, aké rozhodnutia je vhodné robiť na základe výstupu
Organizačné					
10	Nedosiahnutie požadovaných výsledkov	3	9	27	Výber správneho programu pre predikciu a overenie výsledkov modelu

Tabuľka 2 Ohodnotenie rizík a navrhnuté opatrenia⁴¹

3.10 Mapa rizík


Mapa rizík je vytvorená na základe výstupov skórovacej metódy. Podľa umiestnenia rizika môže spadať do štyroch kategórií: bezvýznamné, bežne, významné a kritické. Každá oblasť má rozmer 5x5, najvyššiu pozornosť treba venovať hornej polovici tabuľky. Z priloženej mapy rizík je zrejmé, v akej časti sa nachádzajú jednotlivé riziká.⁴²

⁴¹ Vlastné spracovanie v MS Excel

⁴² RAIS, K. a R. DOSKOČIL. Risk Management. Brno: CERM, 2007, s.76-77. ISBN 978- 80-214-3510-0.

Významné riziko	Kritické riziko
Bezvýznamné riziko	Bežné riziko

Obrázok 11 Rozdelenie rizík v mape⁴³



Obrázok 12 Mapa rizík pred zavedením opatrení⁴⁴

Ako je možné vidieť z mapy rizík, pred prijatím opatrení na zníženie, alebo elimináciu rizík, spadali niektoré riziká do kategórie významných, jedno dokonca medzi kritické.

Opatrenia, tak ako sú uvedené, boli prijaté hlavne za účelom eliminácie rizika, preto väčšina rizík po prijatí opatrení má pravdepodobnosť výskytu rovnú nule. Napriek tomu existujú riziká, ktoré vplyvom opatrenia stále môžu nastať, ale ich dopad je znížený. Pre lepší prehľad bola po prijatí opatrení opäť spracovaná mapa rizík.

⁴³ Vlastné spracovanie v MS Excel

⁴⁴ Vlastné spracovanie v MS Excel

ID	Riziko	P	D	H
1	Nesprávne zvolené vstupné dáta	1	3	3
9	Riaditeľ firmy bude mať problém pracovať s programom samostatne	2	2	4
10	Nedosiachnutie požadovaných výsledkov	1	2	2

Tabuľka 3 Ohodnotenie rizík po prijatí opatrení⁴⁵

Ostatné riziká boli eliminované. nedostatočná funkcionálna program v skúšobnej verzii nemôže nastať, pretože produkt má uvedený presný zoznam funkcií, ktoré táto verzia obsahuje, tým pádom je takisto eliminované riziko, že program by nespĺňal požiadavky, ktoré sú naň kladené.


Hrozba bezpečnostných a finančných rizík je takisto eliminovaná, nakoľko produkt bude obstaraný z oficiálnej stránky spoločnosti OLSOFT a jeho cena je takisto pevne daná.

Rizikami však stále sú nesprávne zvolené vstupné dáta, pravdepodobnosť je však nízka, keďže je popísané, ako vstupné dáta treba voliť. Aj ak by takýto scenár nastal, dopad pre spoločnosť by nebol výrazný, keďže rozhodnutie, v ktorom predikcia pomáha je vykonávané každý mesiac a v doterajšom stave nebola v súvislosti s týmto rozhodnutím robená žiadna predikcia. Takže aj v prípade mierne nepresnej predikcie spoločnosť urobí lepšie rozhodnutie ako v doterajšom stave.

S nesprávne volenými vstupnými dátami súvisí aj dosiahnutie iných než očakávaných výsledkov, takisto však platí, že zmena by aj tak mala pre spoločnosť pozitívny vplyv a pravdepodobnosť výskytu takéhoto javu je nízka.

Riziká, ktoré neboli eliminované, však po prijatí opatrení spadajú medzi bezvýznamné.

⁴⁵ Vlastné spracovanie v MS Excel




Obrázok 13 Mapa rizík po zavedení opatrení⁴⁶

⁴⁶ Vlastné spracovanie v MS Excel

4 NÁVRH RIEŠENIA

V tejto kapitole sú uvedené vstupné dáta, na základe čoho boli vybrané a aký je ich význam pre predikciu. Ďalej je spracované riešenie vo vybranom nástroji na tvorbu predikcií, pomocou neurónových sietí.

Na základe grafu za obdobie posledného roka je zrejmé, že aj pri období jedného mesiaca sa hodnota kurzu výrazne mení a tak má jeho predikcia význam. V súčasnom stave spoločnosti, bez predikcie tohto vývoja, je vplyv rozhodnutia nepredpovedateľný. Prípadne môže byť vybrané lokálne maximum, obdobia posledných dní, nie však globálne maximum za obdobie, v ktorom je možné faktúru zaplatiť.



Obrázok 14 Vývoj konverzného kurzu v testovanom období⁴⁷

4.1 Výber vhodného programu

Pre vytvorenie predikcie boli zohľadnené vlastnosti programov MATLAB od

⁴⁷ *Euro foreign exchange reference rates* [online]. 2019 [cit. 2019-05-05]. Dostupné z: https://www.ecb.europa.eu/stats/policy_and_exchange_rates/euro_reference_exchange_rates/html/eurofxref-graph-huf.en.html

spoločnosti Mathworks, NeuroShell Predictor od spoločnosti Ward Systems, NeuroSolutions Excel od spoločnosti NeuroSolutions Ltd. a NeuroXL Predictor, vytvorený spoločnosťou OLSOFT.

Všetky vybrané programy umožňujú optimalizáciu modelov umelých neurónových sietí a tak je možné ich využiť na predikciu konverzného kurzu, základným hodnotením pre výber programu tak je cena. V nasledujúcej tabuľke sú uvedené ceny licencií jednotlivých programov, v prípade MATLABu sa jedná o ročný poplatok.

Produkt		Cena[v dolároch]
Ward Systems NeuroShellPredictor		445,00
NeuroSolutions Excel		250,00
NeuroXL Predictor		99,95
Matlab		800,00

Tabuľka 4 Ceny jednotlivých programov pre predikciu⁴⁸

Z tabuľky je zrejmé, že najlacnejší je nástroj NeuroXL Predictor, ktorý takisto, narozdiel od ostatných uvedených programov ponúka testovaciu verziu, s dobou platnosti 10 dní.

4.2 Vstupné dáta

Vstupné dáta, ktorými sú historické hodnoty vývoja konverzného kurzu, boli získané z online zdroja *www.investing.com a forex.com*. Pre potreby predikcie a kompatibilitu s vybraným programom NeuroXL Predictor, boli dáta uložené do hárku v programe Microsoft Excel. Na uvedenom obrázku je možné vidieť štruktúru týchto dát.

⁴⁸ Vlastné spracovanie podľa: *White paper artificial intelligence* [online]. 2003 [cit. 2019-05-05]. Dostupné z: http://neuroxl.com/files/white_paper_artificial_intelligence.pdf

Date	ID	Price	Open	High	Low	Change %
26.3.2018	1	312,990	312,760	313,270	312,390	0,03%
27.3.2018	2	312,840	313,030	313,310	312,350	-0,05%
28.3.2018	3	312,435	312,825	313,205	312,135	-0,13%
29.3.2018	4	312,360	312,450	312,980	311,780	-0,02%
30.3.2018	5	312,635	312,375	312,875	311,885	0,09%

Tabuľka 5 Denné hodnoty konverzného kurzu⁴⁹

Význam jednotlivých stĺpcov v tabuľke je nasledovný, Date je dátum, pre ktorý sú zaznamenané historické údaje, pre lepšiu prácu s dátami je každému dňu priradené ID. Open označuje hodnotu, vo forintoch, ktorú má jedno euro pri otvaraní trhu v daný deň. High vyjadruje najvyššiu hodnotu konverzného kurzu v danom dni, naopak Low najnižšiu. Price je hodnota kurzu pri uzatvorení trhu v danom dni, označovaná aj Close, táto hodnota bude sledovaná ako výstupná, pre potreby modelu.

V tabuľke je takisto zobrazený rozdiel v percentách, ktorý vyjadruje zmenu hodnoty konverzného kurzu vzhľadom na predošlý deň. V prípade, že táto hodnota klesla, je zmena vyjadrená záporným číslom.

Ako je zrejmé z nasledjúcej tabuľky, hodnota kurzu sa počas víkendu nemení, a tak je možné tieto dáta zredukovať, aby neurónová sieť pracovala s vhodným množstvom vstupných dát a odstránili sa prebytočné hodnoty. Tento jav je spôsobený uzavretím hlavných trhov počas víkendu, čo má za následok stabilitu konverzného kurzu.

⁴⁹ Vlastné spracovanie podľa: Investing.com [online]. Fusion Media Limited, 2019 [cit. 2019-05-04]. Dostupné z: <https://www.investing.com/currencies/eur-huf-historical-data>

09 4 2018	1	312,1
10 4 2018	1	311,82
11 4 2018	1	311,74
12 4 2018	1	311,4
13 4 2018	1	311,13
14 4 2018	1	311,13
15 4 2018	1	311,13

Tabuľka 6 Hodnota kurzu EUR/HUF počas týždňa⁵⁰

Výsledné vstupné dáta, ktoré sú použité pre predikciu teda majú nasledovný tvar:

Date	ID	Price	Open	High	Low	Change %
26.3.2018	1	312,990	312,760	313,270	312,390	0,03%
27.3.2018	2	312,840	313,030	313,310	312,350	-0,05%
28.3.2018	3	312,435	312,825	313,205	312,135	-0,13%
29.3.2018	4	312,360	312,450	312,980	311,780	-0,02%
30.3.2018	5	312,635	312,375	312,875	311,885	0,09%
2.4.2018	6	312,570	312,320	312,920	312,200	-0,02%
3.4.2018	7	311,915	312,575	312,895	311,605	-0,21%
4.4.2018	8	311,260	311,900	312,450	311,010	-0,21%
5.4.2018	9	311,305	311,285	311,845	310,815	0,01%
6.4.2018	10	312,545	311,235	313,125	310,905	0,40%
9.4.2018	11	311,410	312,350	312,790	311,000	-0,36%
10.4.2018	12	311,335	311,425	312,075	310,895	-0,02%
11.4.2018	13	311,300	311,360	312,160	311,040	-0,01%

Tabuľka 7 Vstupné dáta po odstránení hodnôt zo soboty a nedele⁵¹

Zo vstupných dát teda pre lepšiu predikciu boli odstránené dáta zo soboty a nedele, napríklad 31.3.2018 a 1.4.2018.

Vstupné dáta sú využívané za obdobie jedného roka, konkrétne od 25. marca 2018 do 25. marca 2019. Maximálnym obdobím, ktoré je možné využiť pre vyhotovenie predikcie, je tak jeden rok. Pre predikciu je potrebné tieto dáta

⁵⁰ Vlastné spracovanie podľa: Forex [online]. 2019 [cit. 2019-05-05]. Dostupné z: <https://www.forex.com/en-us/forex-trading/eur-huf/>

⁵¹ Vlastné spracovanie podľa: Investing.com [online]. Fusion Media Limited, 2019 [cit. 2019-05-04]. Dostupné z: <https://www.investing.com/currencies/eur-huf-historical-data>

rozdeliť na tréningové, testovacie a validačné.

Keďže sa v odvetví, v ktorom spoločnosť podniká, nevyskytuje sezónnosť, teda zvýšený dopyt po produktoch v určité časti roka, sú náklady spoločnosti spojené s nákupom tovaru od dodávateľov rovnomerné rozdelené.

Jednotlivé ročné náklady na kúpu materiálu od dodávateľov z Maďarska sú uvedené v nasledujúcej tabuľke. Jednotkou sú tisíce eur.

	ročný náklad	názov materiálu
Materiál 1	222000	polyacetaly
Materiál 2	162000	polyetyleny
Materiál 3	328000	polyamidy
Materiál 4	19000	polyuretany
Materiál 5	72000	polykarbonaty
Materiál 6	58000	komponenty dopravníkov
Materiál 7	42000	teflony

Obrázok 15 Ročné náklady spojené s úhradou faktúr dodávateľom v cudzej mene⁵²

Celkové ročné náklady spoločnosti sú teda 903 000 eur. Pri uvažovanom rovnomernom rozdelení sú tak mesačné náklady spojené s úhradou faktúr v cudzej mene 75 250 eur.

4.2.1 Časové obdobie vstupných dát pre predikciu

Ako bolo uvedené v kapitole *Predikcia*, pre získanie čo najlepších výsledkov predikcie je potrebné správne zvoliť časový interval, v ktorom sú zaznamenané vstupné dáta použité pre predikciu.

Pre potrebu predikcie konverzného kurzu, je potrebné dať pozor na výskyt stochastických javov, ktoré súvisia najmä s politikou daného štátu, konkrétne Maďarska. Ich následkom dochádza k náhlej zmene konverzného kurzu, či už v pozitívnom, alebo negatívnom zmysle.

⁵² Vlastné spracovanie na základe podkladov z firmy TechPlasty s.r.o.

Zahrnutie dát z obdobia, kedy k takémuto javu došlo do predikčného modelu, má za následok zníženú prenosť predikcie a tak aj výsledkov na výstupe. Je to dôsledkom toho, že hodnoty, ktoré sú súčasťou vstupov predikčného modelu, boli v tomto období zmenené vplyvom javov, ktoré predikcia nezahŕňa a v budúcnosti ich nemožno očakávať.

Príkladom je obdobie septembra roku 2018, kedy forint výrazne poklesol vplyvom prijatia odporúčania Európskeho parlamentu, na potrestanie Maďarska za porušenie pravidiel daných Európskou úniou. Na základe tohto rozhodnutia boli zavedené pre Maďarsko sankcie.

Na grafe je vyjadrená hodnota kurzu EUR/HUF, ktorá vplyvom tohto rozhodnutia stúpala.



Obrázok 16 Rast eura po prijatí zákona v EP⁵³

Po najvyššom raste Maďarskej ekonomiky za posledných desať rokov v období, ktoré predchádzalo danej udalosti, tak nastal jav, ktorý spôsobil výrazný pokles hodnoty meny.

⁵³ *Forint Drops as European Lawmakers Propose Hungary Sanctions* [online]. Bloomberg, 2018 [cit. 2019-05-06]. Dostupné z: <https://www.bloomberg.com/news/articles/2018-09-12/forint-weakens-as-european-lawmakers-recommend-hungary-sanctions>

Pri vytváraní predikcie je tak vhodné dbať nato, aby sa v období, za ktoré sú vstupné dáta využité, nevyskytoval takýto výrazný stochastický jav, ktorý ovplyvnil vývoj.


Tento jav však môže nastať v období, pre ktoré je predikcia vytváraná a tým spôsobí jej zvýšenú nepresnosť.

4.3 Riešenie nástrojom NeuroXL Predictor

NeuroXL Predictor je nástroj vyvinutý spoločnosťou OLSOFT, založený na neurónových sieťach. Tento nástroj je doplnkom MS Excelu navrhnutým na vytváranie pokročilých dátových predpovedí.

Plná verzia tohto programu stojí 99,95 dolárov, k dispozícii je však aj demo verzia, s platnosťou 10 dní, ktorá obsahuje všetky funkcie potrebné pre predikciu konverzného kurzu.

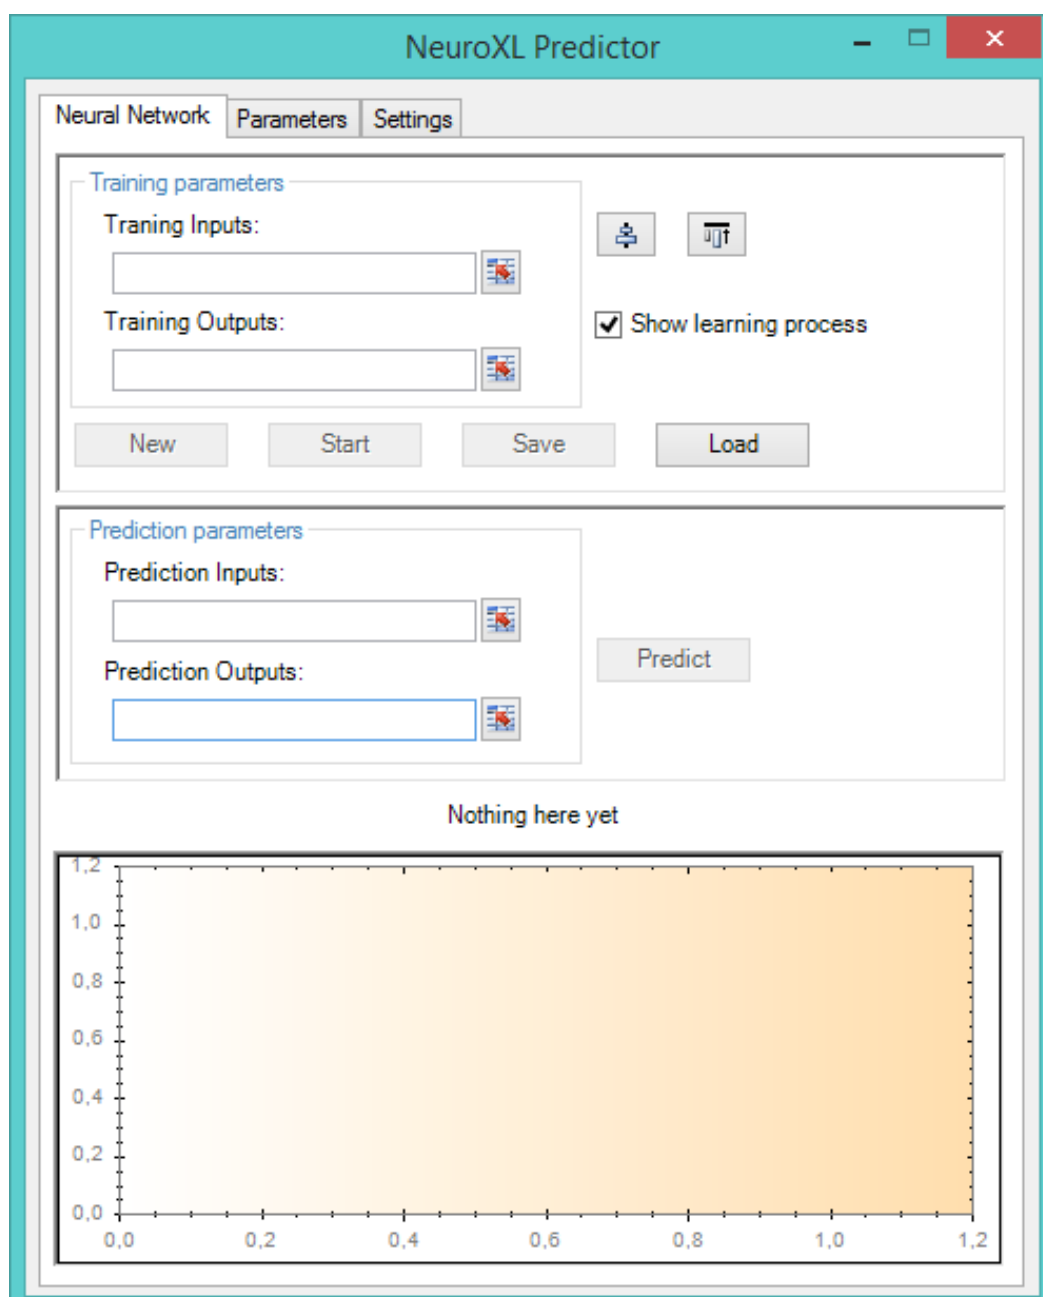
Po úspešnom inštalovaní je po spustení MS Excel k dispozícii doplnok NeuroXL Predictor.



Obrázok 17 Spustenie programu NeuroXL Predictor⁵⁴

⁵⁴ Vlastné spracovanie pomocu MS Excel

Po spustení je k dispozícii nasledovné okno:



Obrázok 18 NeuroXL Predictor GUI⁵⁵

Dáta potrebné pre predikciu sú rozdelené na trénovacie parametre a predikčné parametre.

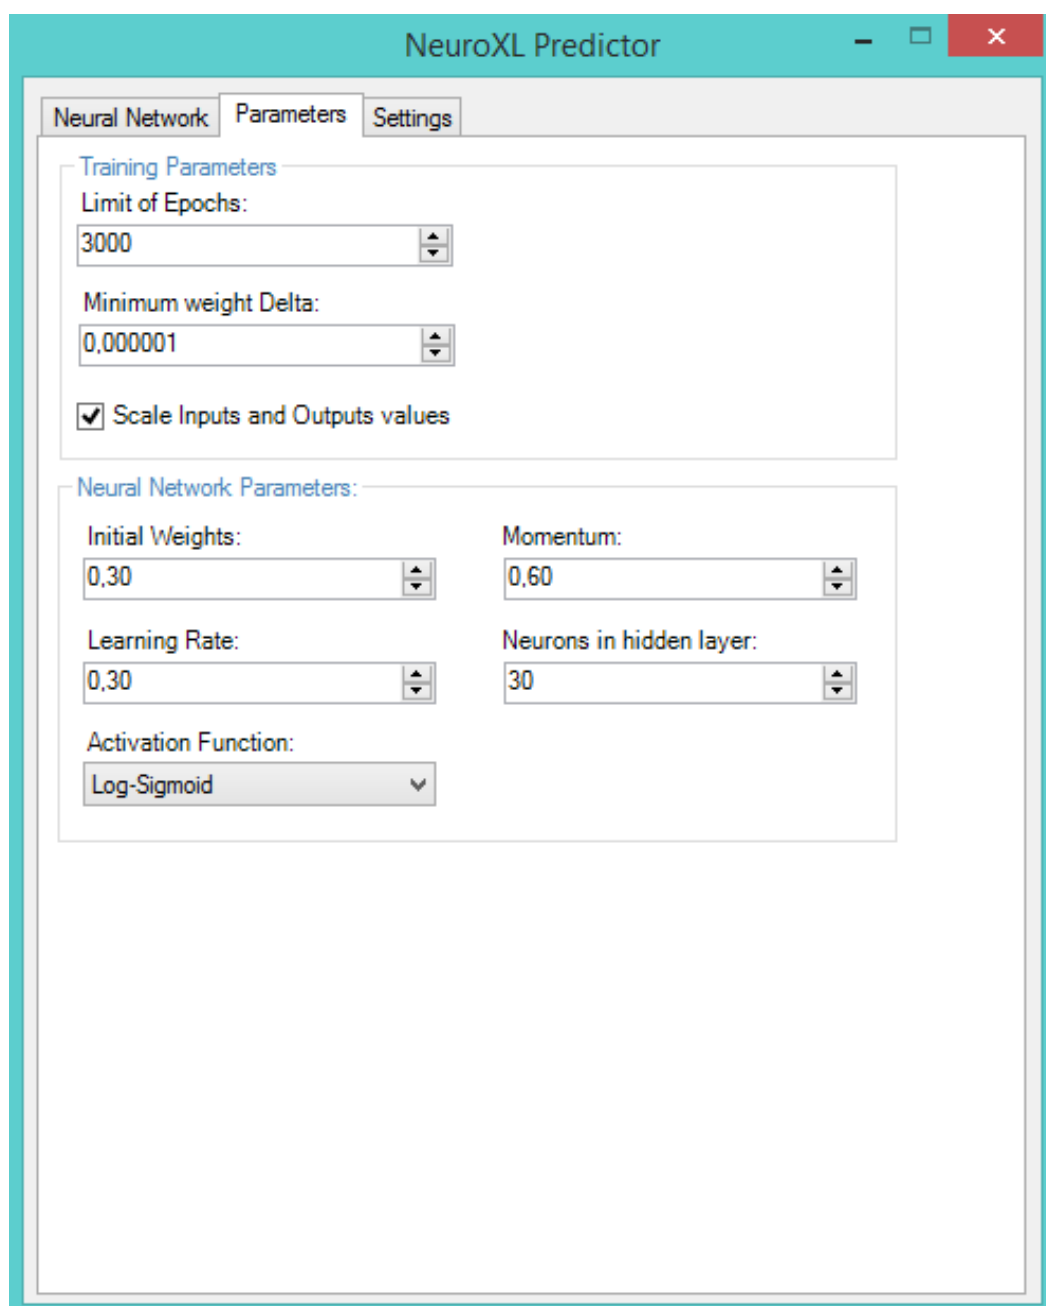
Trénovacie parametre, konkrétne *Training Inputs* a *Training Outputs* sú použité

⁵⁵ Vlastné spracovanie pomocou programu NeuroXL Predictor

na učenie siete. Vstupom sú historické dáta, výstupom potom hodnota kurzu, ktorá bola nameraná pri uzatvorení trhu v danom dni. Po natrénovaní siete sú ako *Prediction Inputs* zvolené dáta namerané v poslednom dni pred obdobím predikcie, výstupom, teda *Prediction Outputs* je hodnota konverzného kurzu na nasledujúci deň.

4.3.1 Proces trénovania siete

Trénovanie, alebo učenie siete, prebieha podľa vopred zvolených parametrov zobrazených na nasledujúcom obrázku. Program NeuroXL Predictor ponúka rôzne možnosti nastavenia týchto parametrov.



Obrázok 19 Parametre neurónovej siete⁵⁶

Limit of Epochs označuje maximálny počet opakovaní, ktorý môže byť dosiahnutý počas trénovania siete. Jedno opakovanie predstavuje kompletný cyklus pri trénovaní s celou množinou trénovacích vstupov. Pokiaľ je počas trénovania dosiahnutá minimálna hodnota *delta*, uvedená v programe ako *Minimum weight*

⁵⁶ Vlastné spracovanie pomocou programu NeuroXL Predictor

Delta, môže byť tento počet cyklov aj nižší a tréning ukončený. Správne nastavenie týchto hodnôt je dôležité, aby hodnota *delta* bola čo najnižšia a predikcia čo najpresnejšia.


V prípade veľkého počtu opakovaní pri nízkej hodnote *delty*, môže dôjsť k preučeniu siete, čo má za následok stav, kedy po tréningovom procese je *delta* vyššia ako bola počas učenia.

V aplikácii NeuroXL Predictor je možné tento tréningový proces sledovať, počas tréningu je priebežne vypisované poradové číslo tréningového cyklu a aj aktuálna hodnota *delty*. Ak sa s ďalším učením *delta* začína zvyšovať, je potrebné učenie zastaviť a parametre tréningu zmeniť.

Takisto je v parametroch možné zvoliť počet neurónov v skrytej vrstve, aktivačnú funkciu, ktorá bude použitá na transformáciu výsledku na výstupnú hodnotu a parameter *learning rate*, ktorý môže nadobúdať hodnoty na intervale $(0,1)$.⁵⁷

Po vytvorení je na grafe, na ktorom je neskôr znázornený priebeh učenia, zobrazený fialovou farbou reálny vývoj hodnôt konverzného kurzu za časové obdobie, v ktorom boli namerané hodnoty použité pre učenie. Zelenou farbou je znázornená predikcia.


⁵⁷ DOSTÁL, Petr, Karel RAIS a Zdeněk SOJKA. *Pokročilé metody manažerského rozhodování: konkrétní příklady využití metod v praxi*. Praha: Grada, 2005., s.115-120 Expert (Grada). ISBN 80-247-1338-1.



Obrázok 20 Počiatočný stav pre učenie siete⁵⁸

Na uvedenom obrázku sú na osy x údaje časového radu, teda poradové číslo dňa, na osy y je nameraná hodnota kurzu v danom dni. V danom prípade bol rozsah vstupných dát 100 dní a na ďalších 10 bude vytvorená predikcia. Vo zvolenom období sa hodnota konverzného kurzu pohybovala v intervale od 315 do 324 forintov za jedno euro.


⁵⁸ Vlastné spracovanie pomocou programu NeuroXL Predictor



Obrázok 21 Priebek učenia neurónovej siete⁵⁹

Počas trénovania siete sa predikčná krivka približuje krivke reálnych hodnôt. Na uvedenom obrázku je trénovanie vo fáze *epochu* číslo 608 a hodnota *delty* je v tomto kroku 0,0077.

⁵⁹ Vlastné spracovanie pomocou programu NeuroXL Predictor



Učenie siete je ukončené buď po vykonaní maximálneho zvoleného počtu *epoch*, alebo pri dosiahnutí minimálnej zvolenej hodnoty *delta*. Po ukončení program vypíše „*Training complete*“ a hodnotu obidvoch veličín. Neurónová sieť je tak pripravená pre predikciu.

4.4 Porovnanie jednotlivých predikcií

Kvalitu predikcie je možné ovplyvniť voľbou začiatku časového radu(krátky rad môže byť rovnako nevhodný ako dlhý rad), ďalej voľbou aktivačnej funkcie, určením rozsahu dát pre testovanie a učenie a parametrom neurónovej siete, najmä počtom neurónov v skrytej vrstve.

Takýto proces sa nazýva ladenie umelej neurónovej siete a patrí medzi nevyhnutné a najobtiažnejšie činnosti pri procese optimalizácie modelu, ak má byť výsledkom kvalitná predikcia.

Keďže umelé neurónové siete sú z hľadiska užívateľov čiernymi skrinkami, záleží na skúsenostiach človeka, ktorý ladenie realizuje a na dobe, ktorá je tejto činnosti

venovaná.⁶⁰

Jednotlivé predikcie budú vyhodnocované podľa strednej relatívnej chyby *MAPE* vyjadrenej v percentách.

4.4.1 Porovnanie podľa začiatku časového radu

Ako bolo spomenuté v predchádzajúcej kapitole, správne zvolenie začiatku časového radu má výrazný vplyv na kvalitu predikcie. Maximálne možné obdobie, ktoré je možné zahrnúť zo vstupných dát do učenia siete je 286 dní, so začiatkom 26.3.2018 a koncom 3.3.2019.

Pre porovnanie boli vybrané aj časové úseky 30, 60 a 90 dní, ako aktivačná funkcia bola zvolená logistická sigmoida a počet neurónov v skrytej vrstve je 5.

Po naučení siete je vytvorená predikcia na obdobie desiatich dní. Absolútna hodnota rozdielu predikovanej hodnoty kurzu a reálnej, a následná suma týchto hodnôt za obdobie desiatich dní, pre ktoré je predikcia vytvorená, je podkladom pre výpočet strednej relatívnej chyby *MAPE*. Aby bola stredná relatívna chyba vyjadrená v percentách, je potrebné ju ešte vynásobiť číslom 100 a vydeliť počtom dní, teda číslom 10.

Počet dní zahrnutých do učenia	Hodnota <i>MAPE</i> [%]
30	0,323621037
60	0,245079504
90	0,156678858
286	0,306987208

Tabuľka 8 Porovnanie strednej relatívnej chyby s meniacim sa počtom dní zahrnutých do učenia⁶¹


⁶⁰ DOSTÁL, Petr, Karel RAIS a Zdeněk SOJKA. *Pokročilé metody manažerského rozhodování: konkrétní příklady využití metod v praxi*. Praha: Grada, 2005., s.120 Expert (Grada). ISBN 80-247-1338-1.

⁶¹ Vlastné spracovanie v MS Excel

Z tabuľky je zrejmé, že najpresnejšia bola predikcia, kedy začiatok časového radu bol 90 dní pred obdobím, na ktoré je predikcia vyhotovená.

S rastúcim počtom dní sa veľkosť chyby znižovala, avšak pri zahrnutí celého súboru vstupných dát sa chyba zvýšila, vplyvom zahrnutia období, kedy došlo k stochastickým javom, ktoré výrazne ovplyvnili vývoj sledovanej výstupnej veličiny. Namerané hodnoty strednej relatívnej chyby sa môžu zdať malé, hodnota okolo 0,3% však predstavuje pri hodnote konverzného kurzu približne 1 forint, čo vzhľadom na reálny vývoj kurzu nieje zanedbateľná hodnota.

Graf porovnania predikčnej a reálnej krivky, pri najúspešnejšej predikcii s 90 dňami zahrnutými do učenia je nasledovný:



Obrázok 22 Porovnanie predikcie s 90 dňami zahrnutými do učenia s reálnym vývojom kurzu⁶²

Ako je možné vidieť na grafe, so zväčšujúcou sa vzdialenosťou od počiatku časovej rady predikcie, rastie aj veľkosť chyby. Predikcia na dlhšie časové obdobie ako 10 dní by teda bola nepresná a jej vplyv na rozhodovací proces by

⁶² Vlastné spracovanie v MS Excel

bol minimálny nakoľko riziko chybovosti je v takom prípade vysoké.

Na základe tejto predikcie by bolo odporúčaným rozhodnutím uskutočniť platbu v štvrtý deň predikovaného obdobia, kedy je hodnota predikovaného kurzu najvyššia a predpokladaná chyba predikcie je vzhľadom na vzdialenosť od začiatku časového radu nízka.

4.4.2 Porovnanie podľa počtu neurónov v skrytej vrstve

V tejto podkapitole budú porovnané predikcie s 90 dňami zahrnutými do učenia modelu, ale rôznym počtom neurónov v skrytej vrstve.


Počet neurónov v skrytej vrstve	Hodnota <i>MAPE</i> [%]
5	0,156678858
10	0,151750606
15	0,15928542
30	0,159625596

Tabuľka 9 Porovnanie strednej relatívnej chyby s meniacim sa počtom neurónov v skrytej vrstve⁶³

Pre testované počty neurónov v skrytej vrstve, s inak nezmenenými parametrami, získanými z experimentov z predchádzajúcej kapitoly sa hodnota strednej relatívnej chyby líšila len minimálne. Najlepšie výsledky predikcie boli dosiahnuté pri modeli s desiatimi neurónmi v skrytej vrstve, zlepšenie oproti modelu, kde v skrytej vrstve bolo 5 neurónov však je len 0,005%.

Pre vyššie počty neurónov v skrytej vrstve vyzerali grafy funkcií nasledovne:

⁶³ Vlastné spracovanie v MS Excel




Obrázok 23 Predikcia so 100 neurónmi v skrytej vrstve⁶⁴

Čas potrebný na tréovanie so stúpajúcim počtom neurónov v skrytej vrstve narastá, keďže jeden epoch je výpočtovo náročnejší. Hodnota relatívnej strednej chyby *MAPE*, sa v tejto konkrétnej predikcii pri ďalšom zvyšovaní počtu neurónov zvyšuje. Experimentom tak bolo dokázané, že predikcia vykazuje najlepšie hodnoty pri počte neurónov od 5 do 30.

Pre potvrdenie tejto tendencie zvyšujúcej sa relatívnej chyby so zvyšujúcim sa počtom neurónov v skrytej vrstve bol ešte uskutočnený jeden experiment.

⁶⁴ Vlastné spracovanie v programe NeuroXL Predictor



Obrázok 24 Predikcia s 300 neurónmi v skrytej vrstve⁶⁵

Pri nastavení parametru počtu neurónov v skrytej vrstve na 300 bola hodnota relatívnej strednej chyby ešte vyššia, takisto čas na výpočet sa predĺžil. Ďalšie experimentovanie so zvyšovaním počtu neurónov tak nemá význam.


4.5 Výsledná predikcia

Po experimentoch s parametrami neurónovej siete a optimalizácií vstupných dát, či už veľkosti časového radu zahrnutého do predikcie, alebo zúžením dát o dni, kedy nedochádzalo k obchodovaniu na trhu, je výsledkom optimalizovaný model na predikciu hodnoty konverzného kurzu.

Na učenie modelu je použitá časová rada o veľkosti 90 dní, s počtom desiatich neurónov v skrytej vrstve a aktivačnou funkciou, ktorou je logistická sigmoida.

⁶⁵ Vlastné spracovanie v programe NeuroXL Predictor

Takto optimalizovaný model poskytuje kvalitné výsledky predikcie, potrebné pre rozhodovanie zvolenej spoločnosti.



Obrázok 25 Porovnanie predikovaných a reálnych hodnôt vybranej predikcie⁶⁶

⁶⁶ Vlastné spracovanie v MS Excel

Dátum	Reálne hodnoty z obdobia 3/2019	Hodnoty získané predikciou
4.3.2019	315,735	316,145
5.3.2019	315,555	315,888
6.3.2019	315,455	316,052
7.3.2019	316,220	317,043
8.3.2019	315,635	314,889
10.3.2019	315,560	316,024
11.3.2019	315,765	315,471
12.3.2019	315,200	315,070
13.3.2019	314,545	315,033
14.3.2019	314,410	314,911

Tabuľka 10 Porovnanie reálnych a predikovaných hodnôt v testovanom období⁶⁷

Dátum	$\left \frac{x_t - \hat{x}_t}{x_t} \right $
4.3.2019	0,001299
5.3.2019	0,001056
6.3.2019	0,001893
7.3.2019	0,002602
8.3.2019	0,002363
10.3.2019	0,001470
11.3.2019	0,000932
12.3.2019	0,000414
13.3.2019	0,001553
14.3.2019	0,001595
Σ	0,015175
MAPE	0,151750606

Tabuľka 11 Výpočet strednej relatívnej chyby⁶⁸

Z výpočtov vyplýva, že hodnota strednej relatívnej chyby pri tejto predikcii je

⁶⁷ Vlastné spracovanie v MS Excel

⁶⁸ Vlastné spracovanie v MS Excel

rovná 0,15%. Hodnota strednej relatívnej chyby bola pri všetkých výpočtoch normovaná na predikované obdobie desiatich dní.

5 VYHODNOTENIE PRÍNOSU

Optimalizovaný predikčný model je po jeho ladení a následnom overení výsledkov na testovacích dátach súčasťou rozhodovacieho procesu vedenia spoločnosti TechPlasty.

Pri výbere dátumu, kedy bude pre spoločnosť najefektívnejšie uhradiť faktúry je dôležité zohľadniť v rozhodovacom procese jednotlivé výsledky predikcie. U každého predikčného modelu klesá pravdepodobnosť kvalitného výstupu s každým ďalším dňom odo dňa, kedy bola predikcia vytvorená.

Na príklade v kapitole 4.2.1 bolo ukázané, že aj pri dlhodobom rastúcom trende kurzu, existuje vždy riziko náhlejšej zmeny, vplyvom nepredvídateľného javu, ktorý predikcia nemôže zahrnúť.

Optimalizovaný predikčný model slúži hlavne na predpovedanie týchto trendov a s ohľadom nato by aj rozhodnutia mali byť uskutočňované. Pokiaľ má hodnota konverzného kurzu predpovedaný rastúci trend, a následne má hodnota stagnovať, tak ako pri testovacích dátach, malo by rozhodnutím byť uhradiť faktúry v termíne kedy sa rast zastaví.

Naopak ak má kurz klesajúci trend, nemala by sa firma spoliehať nato, že v priebehu mesiaca ešte stúpne, ale využiť túto informáciu a faktúry uhradiť predtým než kurz poklesne.

Všeobecné odporúčania, ktoré by vždy viedli k minimalizácii nákladov spojených s prevodom meny neexistujú, ale optimalizovaný model je vhodným nástrojom na podporu rozhodovania.

5.1 Ekonomický prínos

Výstupy predikcie sú ďalej spracované na vyčíslenie ekonomického prínosu pre spoločnosť TechPlasty.

Konkrétny prínos závisí samozrejme od rozhodnutí, ktoré vedenie spoločnosti na základe predikčného modelu urobí. Tieto rozhodnutia závisia od miery rizika, ktoré je vedenie ochotné podstúpiť, ale aj javov, ktoré nastanú počas predikovaného obdobia.

Pred zavedením optimalizovaného predikčného modelu ako nástroja na podporu rozhodovania sa vedenie spoločnosti rozhodovalo spontánne na základe aktuálneho kurzu, kedy faktúry uhradí, nebol teda využívaný žiadny jednotný postup a tak nieje možné povedať, ako by sa v určitom období spoločnosť rozhodla.

Pre vyčíslenie ekonomického prínosu tak budú použité výsledky testovacích dát a budú porovnané s prístupmi, ktoré sú najčastejšie používané medzi firmami.

Mesačné náklady firmy TechPlasty, spojené s nákupom od dodávateľov z Maďarska sú pri aktuálnom kurze 24 381 000 forintov. Ekonomický prínos tak bude vypočítaný ako rozdiel medzi sumou v eurách, ktorá by zodpovedala tejto čiastke v určitý deň na základe predikcie a sumou v deň, kedy by bol prevod uskutočnený bez optimalizovaného predikčného modelu.

Najčastejšie zaužívaným štandardom, ktorý na Slovensku aplikujú aj veľké strojárne závody ako napríklad Volkswagen je uhradiť faktúru vždy 15. deň v mesiaci.

Ak by rovnaký prístup zvolila aj firma TechPlasty v testovacom období by to malo nasledovný dopad:

Dátum	Hodnota v HUF	Konverzný kurz	Hodnota v EUR
15.3.2019	24 381 000	314,35	77 560 €
7.3.2019	24 381 000	316,22	77 101 €

Tabuľka 12 Porovnanie nákladov pri rôznych rozhodnutiach⁶⁹

Výpočtom bolo zistené, že vplyvom rozhodnutia založenom na predikčnom modeli, by spoločnosť za mesiac znížila svoje náklady o 459 eur.

Ďalším často sa vyskytujúcim prípadom je stav, kedy firma platí plní svoje záväzky vždy v posledný deň splatnosti faktúry. Za predpokladu, že firma od dodávateľov nakupuje tovar priebežne, . V období desiatich dní, na ktoré bola predikcia vytvorená tak bude uvažované rovnomerné rozdelenie mesačných nákladov. Spoločnosť teda zaplatí 10% z celkových mesačných nákladov každý deň.

Dátum	Hodnota v HUF	Konverzný kurz	Hodnota v EUR
4.3.2019	2 438 100	315,735	7 722 €
5.3.2019	2 438 100	315,555	7 726 €
6.3.2019	2 438 100	315,455	7 729 €
7.3.2019	2 438 100	316,220	7 710 €
8.3.2019	2 438 100	315,635	7 724 €
10.3.2019	2 438 100	315,560	7 726 €
11.3.2019	2 438 100	315,765	7 721 €
12.3.2019	2 438 100	315,200	7 735 €
13.3.2019	2 438 100	314,545	7 751 €
14.3.2019	2 438 100	314,41	7 755 €
Suma	24 381 000		77 300 €

Tabuľka 13 Hodnota nákladov pri uhrádzaní faktúr v posledný deň splatnosti⁷⁰

Hodnota platby v eurách na základe optimalizovaného predikčného modelu by bola rovnaká ako pri predošlom výpočte, a tak by rozdiel v nákladoch bol 199 eur.

⁶⁹ Vlastné spracovanie v MS Excel

⁷⁰ Vlastné spracovanie v MS Excel

Samozrejme reálne rozdelenie nákladov medzi jednotlivé dni závisí od konkrétneho množstva objednávok v daný deň.

Presná suma, ktorú firma ušetrí vplyvom použitia predikčného modelu tak závisí nielen od nákladov, ktoré v danom období má a intervalu, v ktorom sa kurz v tomto období pohybuje, ale aj od postupov, ktoré boli používané pred zavedením zmeny.

V testovacom období bola predikcia úspešná a na základe získaných výsledkov bol odporučený na úhradu faktúr deň, s najlepšou hodnotou konverzného kurzu za predikované obdobie.

ZÁVER

Cieľom diplomovej práce bolo na základe analýzy navrhnuť oblasť, v ktorej môže vybraná spoločnosť TechPlasty s.r.o. pomocou prvkov umelej inteligencie zlepšiť svoj rozhodovací proces. Na dosiahnutie požadovaných výsledkov boli použité neurónové siete, konkrétne nástroj NeuroXL Predictor.

Optimalizáciou modelu neurónových sietí bola úspešne stanovená predikcia budúcich hodnôt konverzného kurzu eura a forintu. Pomocou tejto predikcie bol zjednodušený rozhodovací proces vo firme spojený s úhradou faktúr v cudzej mene.

Práca sa v návrhovej časti takisto zaoberá vhodným výberom parametrov na optimalizáciu neurónovej siete určenej na takúto predikciu.

Riešenie má pre spoločnosť TechPlasty s.r.o. hlavne ekonomický prínos, ktorý je vyhodnotený v piatej kapitole. Úpravou modelu by bolo možné predikovať aj hodnotu konverzného kurzu eura a inej meny, napríklad českej koruny.

Uplatnenie tohto modelu by malo význam pre množstvo firiem, u ktorých nastáva prevod medzi vybranými menami, nakoľko využívanie umelej inteligencie na predikciu kurzu nieje medzi firmami rozšírené, ale ako bolo dokázané, má význam.

ZDROJE

DOSTÁL, Petr, Karel RAIS a Zdeněk SOJKA. *Pokročilé metody manažerského rozhodování: konkrétní příklady využití metod v praxi*. Praha: Grada, 2005., s.114 Expert (Grada). ISBN 80-247-1338-1.

DOSTÁL, Petr. *Neural Networks and the Shares* [online]. In: ., s. 5 [cit. 2019-05-03]. Dostupné z: <http://www.petrdestal.eu/papers/cla06.pdf>

DOSTÁL, Petr. *Soft computing v podnikatelsví a veřejné správě*. 2015. Brno: Akademické nakladatelství CERM, 2015, str. 22. ISBN 978-80-7204-896-0.

DOSTÁL, Petr. *Soft computing v podnikatelsví a veřejné správě*. 2015., str. 695 Brno: Akademické nakladatelství CERM, 2015. ISBN 978-80-7204-897-7.

EUR-HUF Historical data [online]. Fusion Media Limited, 2019 [cit. 2019-05-04]. Dostupné z: <https://www.investing.com/currencies/eur-huf-historical-data>

Euro foreign exchange reference rates [online]. 2019 [cit. 2019-05-05]. Dostupné z: https://www.ecb.europa.eu/stats/policy_and_exchange_rates/euro_reference_exchange_rates/html/eurofxref-graph-huf.en.html

FORET, Miroslav. *Marketing pro začátečníky*. Brno: Computer Press, 2008. Praxe manažera (Computer Press). ISBN 978-80-251-1942-6.
Forex [online]. 2019 [cit. 2019-05-05]. Dostupné z: <https://www.forex.com/en-us/forex-trading/eur-huf/>

Forint Drops as European Lawmakers Propose Hungary Sanctions [online]. Bloomberg, 2018 [cit. 2019-05-06]. Dostupné z: <https://www.bloomberg.com/news/articles/2018-09-12/forint-weakens-as-european-lawmakers-recommend-hungary-sanctions>

CHANDRA, Reetesh. *Neural networks applications in the real world* [online]. [cit. 2019-05-09]. Dostupné z: <https://www.upgrad.com/blog/neural-networks-applications-in-the-real-world/>

Lecture operations and rules of fuzzy sets [online]. [cit. 2019-05-08]. Dostupné z: http://www.philadelphia.edu.jo/academics/qhamarsheh/uploads/Lecture%2019_Operations%20and%20rules%20of%20fuzzy%20sets.pdf

MAŘÍK, Vladimír, Olga ŠTĚPÁNKOVÁ a Jiří LAŽANSKÝ. *Umělá inteligence*. Praha: Academia, 1993-., s.18 ISBN 80-200-0496-3.

MAŘÍK, Vladimír, Olga ŠTĚPÁNKOVÁ a Jiří LAŽANSKÝ. *Umělá inteligence*. Praha: Serifa, 2003, s. 204. ISBN 80-200-1044-0.

Maxima and minima of functions [online]. [cit. 2019-05-08]. Dostupné z:

<http://xaktly.com/CurveSketching.html>

Prednaska neuronove siete[online]. Bratislava [cit. 2019-05-09]. Dostupné z:

<http://uamt.fei.stuba.sk/MVI/sites/default/files/Prednaska%204%20Neuronove%20siete.pdf>

RAIS, K. a R. DOSKOČIL. Risk Management. Brno: CERM, 2007, s.13. ISBN 978- 80-214-3510-0.

TechPlasty – technické plasty[online]. Žilina [cit. 2019-05-09]. Dostupné z:

<https://www.techplasty.sk>

Transfer function graphs [online]. University San Diego, 2015 [cit. 2019-05-06]. Dostupné z:

<https://edoras.sdsu.edu/doc/matlab/toolbox/nnet/tables14b.html#7752>

White paper artifical intelligence [online]. 2003 [cit. 2019-05-05]. Dostupné z:

http://neuroxl.com/files/white_paper_artificial_intelligence.pdf

PORTER, Michael E. *Konkurenční výhoda: (Jak vytvořit a udržet si nadprůměrný výkon)*. Praha: Victoria Publishing, [1993]. ISBN 80-85605-12-0.

ZOZNAM OBRÁZKOV

Obrázok 1 Rozdiel medzi globálnym a lokálnym extrémom	12
Obrázok 2 Priradovanie hodnôt vo fuzzy logike	14
Obrázok 3 Proces fuzzy spracovania	15
Obrázok 4 Biologický neurón.....	19
Obrázok 5 Umelá neurónová sieť	20
Obrázok 6 Grafy aktivačných funkcií	24
Obrázok 7 Logo spoločnosti TechPlasty	27
Obrázok 8 Model 7S	29
Obrázok 9 Spôsob výpočtu časových ukazateľov v sieťovom grafe	42
Obrázok 10 Sieťový graf	43
Obrázok 11 Rozdelenie rizík v mape	45
Obrázok 12 Mapa rizík pred zavedením opatrení.....	45
Obrázok 13 Mapa rizík po zavedení opatrení.....	47
Obrázok 14 Vývoj konverzného kurzu v testovanom období	48
Obrázok 15 Ročné náklady spojené s úhradou faktúr dodávateľom v cudzej mene	52
Obrázok 16 Rast eura po prijatí zákona v EP	53
Obrázok 17 Spustenie programu NeuroXL Predictor	54
Obrázok 18 NeuroXL Predictor GUI	55
Obrázok 19 Parametre neurónovej siete.....	57
Obrázok 20 Počiatočný stav pre učenie siete	59
Obrázok 21 Priebeh učenia neurónovej siete.....	60
Obrázok 22 Porovnanie predikcie s 90 dňami zahrnutými do učenia s reálnym	

vývojom kurzu	63
Obrázok 23 Predikcia so 100 neurónmi v skrytej vrstve.....	65
Obrázok 24 Predikcia s 300 neurónmi v skrytej vrstve.....	66
Obrázok 25 Porovnanie predikovaných a reálnych hodnôt vybranej predikcie	67

ZOZNAM TABULIEK

Tabuľka 1 Doby trvania jednotlivých činností	41
Tabuľka 2 Ohodnotenie rizík a navrhnuté opatrenia.....	44
Tabuľka 3 Ohodnotenie rizík po prijatí opatrení	46
Tabuľka 4 Ceny jednotlivých programov pre predikciu	49
Tabuľka 5 Denné hodnoty konverzného kurzu.....	50
Tabuľka 6 Hodnota kurzu EUR/HUF počas týždňa	51
Tabuľka 7 Vstupné dáta po odstránení hodnôt zo soboty a nedele.....	51
Tabuľka 8 Porovnanie strednej relatívnej chyby s meniacim sa počtom dní zahrnutých do učenia.....	62
Tabuľka 9 Porovnanie strednej relatívnej chyby s meniacim sa počtom neurónov v skrytej vrstve.....	64
Tabuľka 10 Porovnanie reálnych a predikovaných hodnôt v testovanom období.	68
Tabuľka 11 Výpočet strednej relatívnej chyby	68

ZOZNAM PRÍLOH

PRÍLOHA Č. 1

81

PRÍLOHA Č. 1

Date	ID	Price	Open	High	Low	Change %
26.3.2018	1	312,990	312,760	313,270	312,390	0,03%
27.3.2018	2	312,840	313,030	313,310	312,350	-0,05%
28.3.2018	3	312,435	312,825	313,205	312,135	-0,13%
29.3.2018	4	312,360	312,450	312,980	311,780	-0,02%
30.3.2018	5	312,635	312,375	312,875	311,885	0,09%
2.4.2018	6	312,570	312,320	312,920	312,200	-0,02%
3.4.2018	7	311,915	312,575	312,895	311,605	-0,21%
4.4.2018	8	311,260	311,900	312,450	311,010	-0,21%
5.4.2018	9	311,305	311,285	311,845	310,815	0,01%
6.4.2018	10	312,545	311,235	313,125	310,905	0,40%
9.4.2018	11	311,410	312,350	312,790	311,000	-0,36%
10.4.2018	12	311,335	311,425	312,075	310,895	-0,02%
11.4.2018	13	311,300	311,360	312,160	311,040	-0,01%
12.4.2018	14	311,415	311,325	311,815	311,025	0,04%
13.4.2018	15	310,680	311,430	311,670	310,420	-0,24%
16.4.2018	16	310,265	310,685	311,065	309,985	-0,13%
17.4.2018	17	310,555	310,245	311,275	309,865	0,09%
18.4.2018	18	310,325	310,475	310,755	309,755	-0,07%
19.4.2018	19	310,265	310,285	310,845	310,045	-0,02%
20.4.2018	20	310,830	310,300	311,140	310,100	0,18%
23.4.2018	21	312,375	311,035	312,895	310,505	0,50%
24.4.2018	22	312,445	312,375	313,145	311,965	0,02%
25.4.2018	23	313,000	312,370	313,730	312,150	0,18%
26.4.2018	24	312,875	312,965	313,575	312,505	-0,04%
27.4.2018	25	312,775	312,915	313,305	312,355	-0,03%
30.4.2018	26	313,570	312,730	313,970	312,420	0,25%
1.5.2018	27	314,020	313,510	315,570	313,260	0,14%
2.5.2018	28	314,755	313,915	314,905	312,835	0,23%
3.5.2018	29	313,910	314,800	315,020	313,610	-0,27%
4.5.2018	30	313,770	313,920	314,740	313,370	-0,04%
7.5.2018	31	314,575	313,475	314,945	313,335	0,26%
8.5.2018	32	315,005	314,605	315,565	314,195	0,14%
9.5.2018	33	315,350	314,890	315,840	314,500	0,11%
10.5.2018	34	314,290	315,470	315,870	313,470	-0,34%
11.5.2018	35	315,420	314,310	315,700	313,970	0,36%
14.5.2018	36	315,410	315,510	315,870	314,710	0,00%
15.5.2018	37	316,715	315,335	317,685	314,945	0,41%
16.5.2018	38	316,020	316,720	317,970	315,570	-0,22%
17.5.2018	39	317,150	316,030	317,690	315,590	0,36%
18.5.2018	40	318,385	317,245	318,845	316,825	0,39%

21.5.2018	41	317,845	318,055	319,745	317,535	-0,17%
22.5.2018	42	317,915	317,805	318,925	316,175	0,02%
23.5.2018	43	318,435	317,915	319,925	317,675	0,16%
24.5.2018	44	319,285	318,445	320,115	318,035	0,27%
25.5.2018	45	319,500	319,370	320,490	319,000	0,07%
27.5.2018	46	319,091	319,100	319,115	319,015	-0,13%
28.5.2018	47	318,625	319,515	320,265	318,325	-0,15%
29.5.2018	48	320,825	318,665	321,065	318,395	0,69%
30.5.2018	49	319,725	320,855	321,235	318,935	-0,34%
31.5.2018	50	319,695	319,745	320,115	318,415	-0,01%
1.6.2018	51	320,095	319,625	320,395	319,005	0,13%
3.6.2018	52	320,135	319,725	320,150	319,577	0,01%
4.6.2018	53	318,795	320,165	320,345	318,375	-0,42%
5.6.2018	54	318,705	318,785	319,325	318,115	-0,03%
6.6.2018	55	317,900	318,680	319,300	317,540	-0,25%
7.6.2018	56	318,685	317,935	318,965	316,645	0,25%
8.6.2018	57	319,560	318,680	320,830	318,390	0,27%
10.6.2018	58	319,698	320,125	320,376	319,698	0,04%
11.6.2018	59	321,055	319,645	322,015	319,275	0,42%
12.6.2018	60	319,710	321,040	322,040	319,150	-0,42%
13.6.2018	61	320,600	319,720	321,270	319,360	0,28%
14.6.2018	62	322,905	320,595	323,505	320,345	0,72%
15.6.2018	63	322,535	322,875	324,175	322,045	-0,11%
17.6.2018	64	322,630	322,475	322,728	322,383	0,03%
18.6.2018	65	323,640	322,590	324,310	322,250	0,31%
19.6.2018	66	322,505	323,665	325,455	321,525	-0,35%
20.6.2018	67	323,850	322,530	324,590	321,630	0,42%
21.6.2018	68	326,385	323,785	326,645	323,515	0,78%
22.6.2018	69	324,870	326,460	326,680	323,420	-0,46%
24.6.2018	70	324,620	324,464	324,800	324,240	-0,08%
25.6.2018	71	325,570	324,700	326,530	324,320	0,29%
26.6.2018	72	326,015	325,555	326,585	324,935	0,14%
27.6.2018	73	327,590	325,960	328,380	325,720	0,48%
28.6.2018	74	328,445	327,655	329,115	327,305	0,26%
29.6.2018	75	329,280	328,390	330,330	327,310	0,25%
1.7.2018	76	329,095	329,340	329,428	328,931	-0,06%
2.7.2018	77	330,120	328,610	330,900	328,090	0,31%
3.7.2018	78	327,305	330,155	330,685	326,255	-0,85%
4.7.2018	79	325,425	327,315	327,745	324,795	-0,57%
5.7.2018	80	323,500	325,410	325,890	322,800	-0,59%
6.7.2018	81	323,250	323,470	325,180	322,600	-0,08%
8.7.2018	82	323,362	323,280	323,613	323,280	0,03%
9.7.2018	83	323,600	323,280	324,230	322,390	0,07%
10.7.2018	84	323,960	323,630	326,010	323,420	0,11%
11.7.2018	85	325,565	323,955	325,775	323,645	0,50%

12.7.2018	86	324,705	325,415	325,815	323,985	-0,26%
13.7.2018	87	322,860	324,580	325,120	322,600	-0,57%
15.7.2018	88	323,322	324,332	324,332	323,102	0,14%
16.7.2018	89	323,010	322,580	323,510	321,560	-0,10%
17.7.2018	90	323,780	323,020	323,990	322,600	0,24%
18.7.2018	91	324,000	323,780	324,600	323,230	0,07%
19.7.2018	92	326,505	324,055	327,405	323,825	0,77%
20.7.2018	93	325,440	326,450	327,160	324,960	-0,33%
22.7.2018	94	325,342	325,875	325,897	325,326	-0,03%
23.7.2018	95	326,350	325,460	326,780	325,100	0,31%
24.7.2018	96	326,225	326,305	327,575	325,205	-0,04%
25.7.2018	97	325,565	326,255	326,465	324,825	-0,20%
26.7.2018	98	323,905	325,535	325,915	323,395	-0,51%
27.7.2018	99	322,515	323,875	324,245	321,675	-0,43%
29.7.2018	100	322,509	322,535	322,674	322,206	0,00%
30.7.2018	101	321,750	322,580	323,140	321,370	-0,24%
31.7.2018	102	320,755	321,765	322,135	319,905	-0,31%
1.8.2018	103	320,760	320,790	321,980	320,360	0,00%
2.8.2018	104	321,100	320,700	322,530	320,630	0,11%
3.8.2018	105	320,145	321,095	321,805	319,485	-0,30%
5.8.2018	106	320,108	320,197	320,246	319,712	-0,01%
6.8.2018	107	319,905	320,345	321,055	319,535	-0,06%
7.8.2018	108	320,025	319,885	320,555	319,075	0,04%
8.8.2018	109	319,530	320,040	320,420	318,880	-0,15%
9.8.2018	110	320,740	319,490	321,310	319,020	0,38%
10.8.2018	111	323,275	320,795	324,935	320,175	0,79%
12.8.2018	112	323,288	323,371	324,300	323,118	0,00%
13.8.2018	113	323,205	322,535	325,975	322,255	-0,03%
14.8.2018	114	322,930	323,340	323,760	321,990	-0,09%
15.8.2018	115	324,390	322,840	325,710	322,120	0,45%
16.8.2018	116	323,630	324,540	325,170	323,270	-0,23%
17.8.2018	117	322,650	323,550	324,700	322,370	-0,30%
19.8.2018	118	323,143	323,128	323,351	322,699	0,15%
20.8.2018	119	323,920	322,820	324,180	322,420	0,24%
21.8.2018	120	323,380	323,920	324,600	322,690	-0,17%
22.8.2018	121	322,815	323,465	323,985	322,565	-0,17%
23.8.2018	122	324,475	322,755	325,145	322,645	0,51%
24.8.2018	123	323,490	324,270	324,800	323,070	-0,30%
26.8.2018	124	323,715	323,585	323,807	323,453	0,07%
27.8.2018	125	323,865	323,765	324,255	323,175	0,05%
28.8.2018	126	323,905	323,975	324,665	323,495	0,01%
29.8.2018	127	325,760	323,870	326,290	323,550	0,57%
30.8.2018	128	326,890	325,810	327,360	325,390	0,35%
31.8.2018	129	326,670	326,930	327,500	325,740	-0,07%
2.9.2018	130	326,356	326,360	326,603	326,352	-0,10%

3.9.2018	131	326,960	326,490	327,350	325,960	0,19%
4.9.2018	132	327,810	326,780	328,340	326,300	0,26%
5.9.2018	133	327,495	327,605	329,275	327,145	-0,10%
6.9.2018	134	325,920	327,580	328,650	325,460	-0,48%
7.9.2018	135	324,950	326,050	326,460	324,080	-0,30%
9.9.2018	136	325,160	325,177	325,553	324,659	0,06%
10.9.2018	137	324,980	324,940	326,050	324,130	-0,06%
11.9.2018	138	324,665	324,965	325,265	323,845	-0,10%
12.9.2018	139	325,035	324,695	326,715	324,395	0,11%
13.9.2018	140	324,060	324,980	326,050	323,700	-0,30%
14.9.2018	141	325,025	324,075	325,395	323,075	0,30%
16.9.2018	142	324,856	324,740	325,252	324,418	-0,05%
17.9.2018	143	324,765	324,825	325,525	324,265	-0,03%
18.9.2018	144	323,970	324,810	325,450	322,760	-0,24%
19.9.2018	145	323,145	323,805	324,155	322,605	-0,25%
20.9.2018	146	323,515	323,245	324,575	322,945	0,11%
21.9.2018	147	324,370	323,440	324,480	322,970	0,26%
23.9.2018	148	324,100	323,985	324,158	323,962	-0,08%
24.9.2018	149	323,615	324,145	324,525	323,115	-0,15%
25.9.2018	150	324,335	323,565	324,655	323,145	0,22%
26.9.2018	151	323,555	324,265	324,585	323,135	-0,24%
27.9.2018	152	323,665	323,475	323,955	323,005	0,03%
28.9.2018	153	323,530	323,710	324,860	323,110	-0,04%
30.9.2018	154	323,305	323,400	323,404	323,147	-0,07%
1.10.2018	155	323,105	323,645	324,085	322,645	-0,06%
2.10.2018	156	323,015	323,075	324,205	322,715	-0,03%
3.10.2018	157	322,885	323,125	323,505	322,095	-0,04%
4.10.2018	158	324,305	322,835	325,625	322,545	0,44%
5.10.2018	159	324,735	324,295	325,515	324,025	0,13%
7.10.2018	160	324,738	324,675	324,826	324,560	0,00%
8.10.2018	161	325,435	324,755	325,855	324,425	0,21%
9.10.2018	162	324,460	325,430	325,930	323,970	-0,30%
10.10.2018	163	325,815	324,425	326,015	324,205	0,42%
11.10.2018	164	325,030	325,840	326,150	324,250	-0,24%
12.10.2018	165	324,160	325,020	325,660	323,870	-0,27%
14.10.2018	166	324,278	324,125	324,305	324,003	0,04%
15.10.2018	167	322,700	324,220	324,520	322,120	-0,49%
16.10.2018	168	321,915	322,655	323,135	321,615	-0,24%
17.10.2018	169	322,275	321,905	322,995	321,565	0,11%
18.10.2018	170	323,520	322,180	323,750	321,610	0,39%
19.10.2018	171	323,180	323,540	324,020	322,490	-0,11%
21.10.2018	172	323,040	323,275	323,315	322,745	-0,04%
22.10.2018	173	322,760	322,970	323,460	322,410	-0,09%
23.10.2018	174	323,130	322,720	323,570	322,260	0,11%
24.10.2018	175	323,555	323,135	323,795	321,875	0,13%

25.10.2018	176	324,045	323,625	324,565	323,315	0,15%
26.10.2018	177	324,340	323,950	324,750	323,590	0,09%
28.10.2018	178	324,238	323,956	324,310	323,733	-0,03%
29.10.2018	179	324,810	324,240	324,910	323,540	0,18%
30.10.2018	180	324,635	324,965	325,225	324,245	-0,05%
31.10.2018	181	324,605	324,625	325,665	324,335	-0,01%
1.11.2018	182	322,810	324,690	325,310	322,070	-0,55%
2.11.2018	183	321,785	322,655	323,255	320,875	-0,32%
4.11.2018	184	321,585	321,415	321,918	321,251	-0,06%
5.11.2018	185	321,940	321,830	322,850	321,310	0,11%
6.11.2018	186	321,955	321,955	322,495	321,575	0,00%
7.11.2018	187	321,410	321,990	322,490	321,110	-0,17%
8.11.2018	188	321,045	321,365	321,955	320,705	-0,11%
9.11.2018	189	321,580	321,250	321,880	320,790	0,17%
11.11.2018	190	321,577	321,500	321,906	321,426	0,00%
12.11.2018	191	322,080	321,400	322,560	320,860	0,16%
13.11.2018	192	322,900	322,110	323,870	321,900	0,25%
14.11.2018	193	322,455	322,975	323,565	322,165	-0,14%
15.11.2018	194	322,015	322,375	323,135	321,595	-0,14%
16.11.2018	195	321,705	322,065	322,365	321,225	-0,10%
18.11.2018	196	321,710	321,700	321,745	321,665	0,00%
19.11.2018	197	321,330	321,940	322,160	321,070	-0,12%
20.11.2018	198	321,495	321,285	322,065	320,855	0,05%
21.11.2018	199	321,720	321,500	322,100	320,990	0,07%
22.11.2018	200	321,400	321,720	322,200	320,980	-0,10%
23.11.2018	201	322,600	321,190	322,880	320,820	0,37%
25.11.2018	202	322,352	322,250	322,410	322,250	-0,08%
26.11.2018	203	323,420	322,350	323,940	322,000	0,33%
27.11.2018	204	323,855	323,405	325,175	323,165	0,13%
28.11.2018	205	323,670	323,860	324,670	323,120	-0,06%
29.11.2018	206	323,630	323,730	324,260	322,650	-0,01%
30.11.2018	207	323,620	323,510	324,290	323,150	0,00%
2.12.2018	208	323,712	323,768	323,770	323,545	0,03%
3.12.2018	209	322,625	323,295	324,905	322,035	-0,34%
4.12.2018	210	323,740	322,600	324,080	322,270	0,35%
5.12.2018	211	323,350	323,650	324,200	323,020	-0,12%
6.12.2018	212	323,005	323,395	324,415	322,835	-0,11%
7.12.2018	213	323,135	323,005	324,115	322,505	0,04%
9.12.2018	214	323,237	323,310	323,310	323,014	0,03%
10.12.2018	215	323,630	322,980	323,980	322,760	0,12%
11.12.2018	216	323,685	323,485	324,145	323,045	0,02%
12.12.2018	217	322,950	323,620	323,950	322,670	-0,23%
13.12.2018	218	323,710	322,990	323,910	322,570	0,24%
14.12.2018	219	323,765	323,685	324,535	323,005	0,02%
16.12.2018	220	323,650	323,649	323,667	323,620	-0,04%

17.12.2018	221	323,435	323,685	323,955	322,915	-0,07%
18.12.2018	222	322,240	323,360	323,780	321,940	-0,37%
19.12.2018	223	322,800	322,260	323,190	322,030	0,17%
20.12.2018	224	321,445	322,765	323,065	321,205	-0,42%
21.12.2018	225	322,180	321,430	322,550	321,010	0,23%
23.12.2018	226	322,063	321,925	322,354	321,911	-0,04%
24.12.2018	227	321,320	322,350	322,440	320,750	-0,23%
25.12.2018	228	320,420	321,320	322,020	320,260	-0,28%
26.12.2018	229	321,030	320,460	322,330	320,100	0,19%
27.12.2018	230	321,015	321,005	321,845	320,605	0,00%
28.12.2018	231	321,470	320,990	322,540	320,690	0,14%
30.12.2018	232	321,755	321,625	321,812	321,473	0,09%
31.12.2018	233	321,165	321,225	322,115	320,725	-0,18%
1.1.2019	234	321,325	320,975	323,405	319,925	0,05%
2.1.2019	235	322,270	321,360	322,750	321,030	0,29%
3.1.2019	236	321,340	322,270	323,880	320,750	-0,29%
4.1.2019	237	320,835	321,295	321,935	320,655	-0,16%
6.1.2019	238	320,925	320,835	321,160	320,605	0,03%
7.1.2019	239	321,205	320,705	321,635	320,595	0,09%
8.1.2019	240	321,730	321,230	322,600	320,910	0,16%
9.1.2019	241	321,445	321,675	322,135	321,035	-0,09%
10.1.2019	242	321,340	321,480	322,040	320,850	-0,03%
11.1.2019	243	321,040	321,350	321,980	320,890	-0,09%
13.1.2019	244	321,250	321,040	321,575	320,465	0,07%
14.1.2019	245	321,940	321,170	322,010	320,460	0,21%
15.1.2019	246	323,060	321,820	323,740	321,440	0,35%
16.1.2019	247	321,615	323,125	324,305	321,165	-0,45%
17.1.2019	248	319,645	321,485	322,435	319,055	-0,61%
20.1.2019	250	317,940	318,205	319,230	317,760	-0,02%
21.1.2019	251	317,525	318,125	319,225	317,305	-0,13%
22.1.2019	252	318,115	317,595	318,495	317,275	0,19%
23.1.2019	253	318,045	318,075	318,585	317,765	-0,02%
24.1.2019	254	318,795	318,045	319,505	317,795	0,24%
25.1.2019	255	317,585	318,795	319,095	317,375	-0,38%
27.1.2019	256	317,685	317,790	317,990	317,425	0,03%
28.1.2019	257	317,285	317,785	318,165	317,175	-0,13%
29.1.2019	258	317,125	317,365	317,885	316,965	-0,05%
30.1.2019	259	315,555	317,145	317,625	314,945	-0,50%
31.1.2019	260	316,005	315,595	316,575	315,065	0,14%
1.2.2019	261	317,465	315,915	318,735	315,415	0,46%
3.2.2019	262	317,430	317,385	317,855	317,155	-0,01%
4.2.2019	263	317,595	317,595	318,365	317,055	0,05%
5.2.2019	264	317,880	317,540	318,140	317,000	0,09%
6.2.2019	265	318,700	317,630	319,210	317,310	0,26%
7.2.2019	266	319,085	318,685	319,905	318,415	0,12%

8.2.2019	267	319,105	318,875	319,515	317,775	0,01%
10.2.2019	268	319,055	319,110	319,310	318,680	-0,02%
11.2.2019	269	319,995	319,025	320,295	318,405	0,29%
12.2.2019	270	318,110	320,110	320,290	317,530	-0,59%
13.2.2019	271	319,065	318,145	319,545	317,355	0,30%
14.2.2019	272	318,465	319,175	320,095	318,055	-0,19%
15.2.2019	273	318,085	318,445	319,215	317,825	-0,12%
17.2.2019	274	318,020	318,125	318,475	317,815	-0,02%
18.2.2019	275	317,935	317,925	318,555	317,655	-0,03%
19.2.2019	276	317,585	317,955	318,755	317,055	-0,11%
20.2.2019	277	317,230	317,580	318,090	316,610	-0,11%
21.2.2019	278	317,730	317,280	318,170	316,740	0,16%
22.2.2019	279	318,070	317,690	318,380	317,140	0,11%
24.2.2019	280	317,955	318,070	318,135	317,320	-0,04%
25.2.2019	281	317,905	317,875	318,325	317,035	-0,02%
26.2.2019	282	316,795	318,105	318,335	316,325	-0,35%
27.2.2019	283	316,200	316,560	317,200	315,900	-0,19%
28.2.2019	284	315,835	316,355	316,775	315,465	-0,12%
1.3.2019	285	316,435	315,885	316,615	315,535	0,19%
3.3.2019	286	315,915	316,325	316,980	315,795	-0,16%
4.3.2019	287	315,735	316,445	316,945	315,475	-0,06%
5.3.2019	288	315,555	315,795	316,195	315,275	-0,06%
6.3.2019	289	315,455	315,565	316,045	315,225	-0,03%
7.3.2019	290	316,220	315,430	316,660	314,960	0,24%
8.3.2019	291	315,635	316,245	316,725	315,155	-0,18%
10.3.2019	292	315,560	315,715	315,770	315,155	-0,02%
11.3.2019	293	315,765	315,505	316,255	315,155	0,06%
12.3.2019	294	315,200	315,630	315,990	314,860	-0,18%
13.3.2019	295	314,545	315,185	315,445	314,235	-0,21%
14.3.2019	296	314,410	314,590	314,940	314,100	-0,04%
15.3.2019	297	314,350	314,510	314,790	314,120	-0,02%
17.3.2019	298	314,465	314,390	314,630	314,125	0,04%
18.3.2019	299	313,935	314,035	314,585	313,415	-0,17%
19.3.2019	300	313,040	313,930	314,330	312,890	-0,29%
20.3.2019	301	313,725	313,145	314,745	312,605	0,22%
21.3.2019	302	314,870	313,710	315,150	313,130	0,36%
22.3.2019	303	317,120	314,880	317,120	313,850	0,71%
24.3.2019	304	316,425	317,135	317,135	316,135	-0,22%
25.3.2019	305	316,170	317,300	317,440	315,630	-0,08%

Príloha 1 Vstupné dáta